

UNIVERZITA KARLOVA V PRAZE

Přírodovědecká fakulta

Katedra aplikované geoinformatiky a kartografie

Studijní program: Geografie (navazující magisterské studium)

Studijní obor: Kartografie a geoinformatika



Filip Raasch

**VYUŽITÍ LABORATORNÍ A OBRAZOVÉ SPEKTROSKOPIE PRO HODNOCENÍ
ODOLNOSTI BOROVICE LESNÍ VŮČI SUCHU A ROZLIŠENÍ JEJICH EKOTYPŮ**

**USE OF LABORATORY AND IMAGE SPECTROSCOPY TO EVALUATE
DROUGHT RESISTANCE OF SCOTS PINE AND TO DISTINGUISH ITS
ECOTYPES**

Diplomová práce

Vedoucí diplomové práce: doc. RNDr. Lucie Kupková, Ph.D.

Konzultantka: Mgr. Zuzana Lhotáková, Ph.D.

Praha 2021

Zadání diplomové práce

pro Filipa Raasche

obor Kartografie a geoinformatika

Název tématu: Využití laboratorní a obrazové spektroskopie pro hodnocení odolnosti borovice lesní vůči suchu a rozlišení jejich ekotypů

Zásady pro vypracování:

Práce vychází z bilaterálního projektu Interaction (Česko-USA): „Využití genetické variability hyperspektrální odrazivosti ekotypů borovice lesní pro selekci jedinců odolných vůči suchu“. Cílem práce bude sledovat změny ve spektrálním projevu semenáčků borovice lesní pěstovaných v růstových komorách jednak ve standardních podmínkách a dále v podmínkách simulovaného sucha a zjistit, zda a jakým způsobem se poškození rostlin projeví v jejich spektrálním projevu a zároveň zda budou patrné rozdíly ve spektrální odezvě několika sledovaných fenotypů borovice. Spektrální projev bude sledován s využitím laboratorního spektoradiometru (laboratorní spektra) a v případě nalezení vhodného technického řešení budou pořízena a vyhodnocena také obrazová spektra. Spektrální data budou korelována s dalšími charakteristikami, které budou v rámci experimentu získány kolegy z katedry experimentální biologie rostlin, a svědčí též o fyziologickém stavu rostlin (měření obsahu vody, chlorofylu, případně další).

Rozsah grafických prací: Dle potřeby

Rozsah průvodní zprávy: Cca 70 stran

Seznam odborné literatury:

van Aardt, J., Wynne, R. (2007). Examining pine spectral separability using hyperspectral data from an airborne sensor: An extension of field-based results. *International Journal of Remote Sensing*. 28, 431-436.

Danusevicius, D., Masaitis, G., Mozgeris, G. (2014). Visible and near infrared hyperspectral imaging reveals significant differences in needle reflectance among Scots pine provenances. *Silvae Genetica*. 63, 169-180.

Chávez, R., Clevers, J., Herold, M., Ortiz, M., Acevedo, E. (2013). Modelling the spectral response of the desert tree *Prosopis tamarugo* to water stress. *International Journal of Applied Earth Observation and Geoinformation*. 21, 53-65.

Sundblad, L., Andersson, M., Geladi, P., Salomonson, A., Sjöström, M. (2001). Fast, non-destructive measurement of frost hardiness in conifer seedlings by VIS plus NIR spectroscopy. *Tree physiology*. 21, 751-757.

Stimson, H., Breshears, D., Ustin, S., Kefauver, S. (2005). Spectral sensing of foliar water conditions in two co-occurring conifer species: *Pinus edulis* and *Juniperus monosperma*. *Remote Sensing of Environment*. 96, 108-118.

Wang, X., Zeng, Y., Wang, S. (2015). Identification of Conifer Species Based on Laboratory Spectroscopy and an Artificial Neural Network. *Journal of Software Engineering*. 9, 362-372.

Vedoucí diplomové práce: doc. RNDr. Lucie Kupková, Ph.D.

Datum zadání diplomové práce: 26.11.2019

Termín odevzdání diplomové práce: srpen 2021

.....
Vedoucí diplomové práce

.....
Garant studijního oboru

V Praze dne 30.11.2020

Prohlášení

Prohlašuji, že jsem závěrečnou práci zpracoval samostatně a že jsem uvedl všechny použité informační zdroje a literaturu. Tato práce ani její podstatná část nebyla předložena k získání jiného nebo stejného akademického titulu.

V Praze dne 24.8.2021

.....
Filip Raasch

Poděkování

V první řadě bych chtěl velice poděkovat vedoucí této práce doc. RNDr. Lucie Kupkové, Ph.D. za mnohé rady, věnovaný čas, plánování laboratorního experimentu a podporu při psaní této práce. Dále moc děkuji Mgr. Zuzaně Lhotákové, Ph.D. za trpělivé vysvětlování biologických souvislostí a dohlížení na zdárný průběh laboratorního měření. Mgr. Evě Neuwirthové a RNDr. Jaroslavu Čeplovi, Ph.D. děkuji za pomoc se smíšenými statistickými modely. Ing. Janu Stejskalovi, Ph.D. patří dík za zajištění semenáčků borovice lesní pro laboratorní experiment a za informace k semenným sadům. V neposlední řadě chci poděkovat Bc. Kristýně Štěpánové a Miroslavu Bartákovi za spoluúčast na laboratorních měřeních a za podnětné diskuse vedené i za naprosté tmy. Všem dalším, kteří se přímo i nepřímo podíleli na laboratorním experimentu, patří velký dík.

Abstrakt

Cílem této práce bylo navrhnout nedestruktivní způsob měření semenáčků borovice lesní (*Pinus sylvestris*), zjistit, zda se v laboratorních spektrech borovic projeví stres z nedostatku vody, porovnat, zda se bude reakce borovic lišit dle ekotypu a zkoumat, zda z obrazových a laboratorních spekter bude možné odlišit dva ekotypy borovice lesní. K tomuto účelu byla zpracována obrazová hyperspektrální data semenných sadů ze srpna 2020 a byl proveden tříměsíční laboratorní experiment, v rámci něhož byl u dvouletých semenáčků borovice z náhorního a pahorkatinného ekotypu navozen stres z nedostatku vody. Analýza spektrálních dat proběhla s pomocí smíšených statistických modelů, analýzy rozptylu, analýzy hlavních komponent, natrénování klasifikátorů řízené pixelové klasifikace, vegetačních indexů a lineární regrese. Z analýz bylo zjištěno, že lze detekovat vodní stres u silně stresovaných semenáčků borovice lesní. Nejcitlivější spektrální pásma na obsah vody byla pozorována v oblasti mezi 1000-2500 nm. Počáteční reakce na stres z nedostatku vody se dle ekotypu nelišila, u náhorního ekotypu však byla pozorována rychlejší regenerace po etapě sucha. Dva ekotypy borovice lesní bylo možné s vysokou přesností odlišit jak z laboratorních, tak obrazových dat. I přes vysokou variabilitu mezi jedinci způsobenou vodním stresem bylo možné rozlišit dva ekotypy pomocí lineární diskriminační analýzy s přesností vyšší než 87 % při všech měřeních.

Klíčová slova: semenné sady, borovice lesní (*Pinus sylvestris*), ekotypy, laboratorní spektrometrie, obrazová spektroskopie, analýza rozptylu, řízená pixelová klasifikace, vegetační indexy, vodní stres, sucho

Abstract

The aim of this study was to propose a non-destructive method for measuring *Pinus sylvestris* seedlings, to determine whether water stress would be evident in laboratory spectra of pines, to compare whether the response of pines would differ by ecotype, and to investigate whether two ecotypes of *Pinus sylvestris* could be distinguished using laboratory and image spectroscopy. For these purposes, hyperspectral images of seed orchards from August 2020 were processed and a three-month laboratory experiment was conducted, in which stress from water deficit was induced in two-year-old pine seedlings from the upland and hilly ecotypes. Spectral data were analysed using mixed statistical models, analysis of variance, principal component analysis, training of supervised pixel classifiers, vegetation indices, and linear regression. Based on the analyses, it was found that water stress can be detected in severely stressed *Pinus sylvestris* seedlings. The most sensitive spectral bands to water content were observed in the region between 1000-2500 nm. The initial response to water stress did not differ by ecotype, but a faster recovery was observed at the upland ecotype after the period of

draught. The two *Pinus sylvestris* ecotypes were distinguished with high accuracy from both laboratory and image spectral data. Despite the high inter-individual variability caused by water deficit stress, it was possible to distinguish the two ecotypes using linear discriminant analysis with an accuracy of more than 87 % in all measurements.

Key words: seed orchards, *Pinus sylvestris*, ecotypes, laboratory spectrometry, image spectroscopy, analysis of variance, supervised pixel classification, vegetation indices, water deficit stress, drought

Obsah

1	ÚVOD A CÍLE PRÁCE	13
2	LITERÁRNÍ REŠERŠE A ÚVOD DO PROBLEMATIKY	15
2.1	SPEKTROSKOPIE	15
2.1.1	Laboratorní spektroskopie	15
2.1.2	Obrazová spektroskopie	18
2.1.3	Metody pro vyhodnocení spektroskopických dat	19
2.2	BOROVICE LESNÍ	23
2.2.1	Ekotypy borovice lesní a semenné sady v ČR	23
2.2.2	Indikátory stresu z nedostatku vody	24
2.3	SPEKTROSKOPICKÉ METODY PRO DETEKCI SUCHA	25
2.4	ODLIŠENÍ EKOTYPŮ A GENOTYPŮ POMOCÍ SPEKTROSKOPIE	27
3	DATA A METODIKA	29
3.1	OBRAZOVÁ HYPERSPEKTRÁLNÍ DATA	29
3.1.1	Zájmové území	29
3.1.2	Data hyperspektrální kamery Nano-Hyperspec®	30
3.1.3	Extrakce spekter požadovaných jedinců	31
3.1.4	Analýza obrazových spektrálních dat	32
3.2	LABORATORNÍ SPEKTRA	33
3.2.1	Průběh měření	33
3.2.2	Způsob měření a přístroje	35
3.2.3	Úprava spekter s pomocí fotografií semenáčků	38
3.2.4	Analýza laboratorních spekter	40
4	VÝSLEDKY	43
4.1	ANALÝZA OBRAZOVÝCH HYPERSPEKTRÁLNÍCH DAT	43
4.1.1	Analýza rozptylu (ANOVA)	43
4.1.2	PCA a natrénování klasifikátorů	44
4.2	ANALÝZA LABORATORNÍCH SPEKTER	46
4.2.1	Vliv úpravy spekter s pomocí fotografií semenáčků	46
4.2.2	Smíšené modely	47
4.2.3	Analýza rozptylu (ANOVA)	48
4.2.4	PCA a Natrénování klasifikátorů	53
4.2.5	Vegetační indexy	57
4.3	VZTAH MEZI LABORATORNÍMI SPEKTRY A DALŠÍMI INDIKÁTORY STRESU	60
4.3.1	Vývoj obsahu chlorofylu	60

4.3.2	<i>Vývoj obsahu vody v půdě</i>	61
4.3.3	<i>Regrese mezi spektrálními daty a obsahem chlorofylu z CCM</i>	63
4.3.4	<i>Regrese mezi spektrálními daty a laboratorně stanoveným obsahem chlorofylu.....</i>	65
4.3.5	<i>Regrese mezi spektrálními daty a obsahem vody v jehlicích</i>	68
5	DISKUSE.....	71
6	ZÁVĚR	79
	SEZNAM LITERATURY	81
	PŘÍLOHY.....	86

Seznam obrázků

Obrázek 1: Přehled semenných sadů (vlastní zpracování), podkladová mapa z www.mapy.cz	29
Obrázek 2: Hyperspektrální kamera Nano-Hyperspec® (Headwall 2021).....	30
Obrázek 3: Část polygonů, ze kterých byly extrahovány pixely stromů	31
Obrázek 4: Klasifikace k-means	32
Obrázek 5: Časová osa laboratorního experimentu	35
Obrázek 6: Diagram soustavy pro měření spektrálních dat	36
Obrázek 7: Fotografie z měření semenáčku borovice.....	37
Obrázek 8: Fotografie štítu s pravítkem a místem, kam míří optický kabel.	38
Obrázek 9: Část borovice v zorném poli optického kabelu s odmaskovaným pozadím.	40
Obrázek 10: Analýza rozptylu pro dva ekotypy	43
Obrázek 11: Analýza rozptylu pro tři semenné sady.....	43
Obrázek 12: Hodnoty EigenVectors pro PCA ze semenných sadů.....	44
Obrázek 13: Plot hodnot první a druhé hlavní komponenty pro tři semenné sady	45
Obrázek 14: Variační koeficient před a po úpravě hodnot odrazivosti	46
Obrázek 15: Smíšený statistický model - ekotypy	47
Obrázek 16: Smíšený statistický model - rozdíl mezi mírou zálivky	48
Obrázek 17: ANOVA dle ekotypů 29.4.2021 (2. měření)	48
Obrázek 18: ANOVA dle ekotypů 24.6.2021 (10. měření)	49
Obrázek 19: ANOVA dle míry zálivky 22.4.2021 (1. měření)	50
Obrázek 20: ANOVA dle míry zálivky 24.6.2021 (10. měření).....	51
Obrázek 21: ANOVA dle míry zálivky 15.7.2021 (12. měření).....	51
Obrázek 22: Hodnoty EigenVectors pro PCA z laboratorních spekter.....	53
Obrázek 23: Plot hodnot první a druhé hlavní komponenty dle dvou ekotypů 22.4.2021	53
Obrázek 24: Plot hodnot první a druhé hlavní komponenty dle dvou ekotypů 24.6.2021	53
Obrázek 25: Plot hodnot první a druhé hlavní komponenty dle míry zálivky 22.4.2021	54
Obrázek 26: Plot hodnot první a druhé hlavní komponenty dle míry zálivky 24.6.2021	54
Obrázek 27: Vývoj NDVI - náhorní ekotyp.....	57
Obrázek 28: Vývoj NDVI - pahorkatinný ekotyp	57
Obrázek 29: Vývoj TCARI/OSAVI - náhorní ekotyp.....	57
Obrázek 30: Vývoj TCARI/OSAVI - pahorkatinný ekotyp	57
Obrázek 31: Vývoj MSI - náhorní ekotyp.....	58
Obrázek 32: Vývoj MSI - pahorkatinný ekotyp.....	58
Obrázek 33: Vývoj NDWI - náhorní ekotyp	58

Obrázek 34: Vývoj NDWI - pahorkatinný ekotyp	58
Obrázek 35: Vývoj WBI – náhorní ekotyp	59
Obrázek 36: Vývoj WBI – pahorkatinný ekotyp	59
Obrázek 37: Vývoj obsahu chlorofylu - náhorní ekotyp	60
Obrázek 38: Vývoj obsahu chlorofylu – pahorkatinný ekotyp	60
Obrázek 39: Rozdíl obsahu chlorofylu od kontroly – náhorní ekotyp	60
Obrázek 40: Rozdíl obsahu chlorofylu od kontroly - pahorkatinný ekotyp	60
Obrázek 41: Vývoj obsahu vody v půdě (nezávisle na ekotypu)	61
Obrázek 42: Rozdíl obsahu vody od kontrolní skupiny (nezávisle na ekotypu)	62
Obrázek 43: Míra korelace mezi obsahem chlorofylu (z CCM) a odrazivostí v každé vlnové délce.....	63
Obrázek 44: Plot mezi obsahem chlorofylu (z CCM) a odrazivostí v 548 nm.....	64
Obrázek 45: Míra korelace mezi obsahem chlorofylu (laboratorně stanoveným) a odrazivostí v každé vlnové délce.....	65
Obrázek 46: Plot mezi hodnotami odrazivosti v 543 nm a laboratorně stanoveným obsahem chlorofylu	66
Obrázek 47: Vývoj indexu 680/610 nm - náhorní ekotyp	67
Obrázek 48: Vývoj indexu 680/610 nm - pahorkatinný ekotyp	67
Obrázek 49: Míra korelace mezi obsahem vody a odrazivostí v každé vlnové délce	68
Obrázek 50: Plot mezi obsahem vody a odrazivostí v 1885 nm	69
Obrázek 51: Vývoj indexu 1880/2130 nm – náhorní ekotyp	70
Obrázek 52: Vývoj indexu 1880/2130 nm - pahorkatinný ekotyp	70

Seznam tabulek

Tabulka 1: Základní údaje o semenných sadech. Vytvořeno podle Provazníka (2021).	30
Tabulka 2: Datum a čas pořízení hyperspektrálních dat	30
Tabulka 3: Počet měřených jedinců dle ekotypu a míry stresu	34
Tabulka 4: Objem, čas a datum zálivky dle skupin ošetření.....	34
Tabulka 5: Přesnosti natrénování klasifikátorů (semenné sady)	45
Tabulka 6: Počet spektrálních pásem, ve kterých jsou p-hodnoty pro ANOVU dle ekotypů nižší než 0,05	50
Tabulka 7: Počet spektrálních pásem, ve kterých jsou p-hodnoty pro ANOVU dle zálivky nižší než 0,05	52
Tabulka 8: Přesnosti natrénování klasifikátorů (2 ekotypy).....	54
Tabulka 9: Přesnosti natrénování klasifikátorů (3 ošetření, nezávisle na ekotypu).....	55
Tabulka 10: Přesnosti natrénování klasifikátorů (náhorní ekotyp, 2 skupiny ošetření - silné sucho, zbytek)	55
Tabulka 11: Přesnosti natrénování klasifikátorů (pahorkatinný ekotyp, 2 skupiny ošetření - silné sucho, zbytek).....	56
Tabulka 12: Poměry pásem s nejvyšší hodnotou koeficientu determinace (obsah chlorofylu z CCM x spektra).....	64
Tabulka 13: Korelace obsahu chlorofylu z CCM s vybranými vegetačními indexy.....	64
Tabulka 14: Poměry pásem s nejvyšší hodnotou koeficientu determinace (obsah laboratorně stanoveného chlorofylu x spektra).....	66
Tabulka 15: Korelace laboratorně stanoveného chlorofylu s vybranými vegetačními indexy	66
Tabulka 16: Poměry pásem s nejvyšší hodnotou koeficientu determinace (obsah vody x spektra)	69
Tabulka 17: Korelace obsahu vody s vybranými vegetačními indexy	69

Seznam zkratek

AI	Absorption Index
ANN	Artificial Neural Network
ANOVA	Analysis of Variance
AVIRIS	Airborne Visible/Infrared Imaging Spectrometer
AUC	Area Under Curve
CCM / CCM-300	Chlorophyll Content Meter 300
CRI	Carotenoid Reflectance Index
DN	Digital Number
EPF	Edge Preserving Filter
GMM	Gaussian Mixture Models
GPS	Global Positioning System
Chap	Chappel Index
ISODATA	Iterative Self-Organizing Data Analysis Technique
KNN	K-th Nearest Neighbour
LDA	Linear Discriminant Analysis
MDA	Multiple Discriminant Analysis
NDSI	Normalized Difference Spectral Index
NDVI	Normalized Difference Vegetation Index
NDWI	Normalized Difference Water Index
MBD	Maximum Band Depth
MCARI	Modified Chlorophyll Absorption Ratio Index
MSI	Moisture Stress Index
PCA	Principal Component Analysis
PLS	Partial Least Square
RVI	Ratio Vegetation Index
SAM	Spectral Angle Mapper
SVM	Support Vector Machine
TCARI/OSAVI	Transformed Chlorophyll Absorption Ratio Index / Optimised Soil Adjusted Vegetation Index
WBI	Water Band Index
WI	Water Index

1 Úvod a cíle práce

Krajinu střední Evropy trápí sucho a dle predikcí vývoje klimatické změny se bude projevovat čím dál více (AVex 2019). Nedostatek vody má za důsledek mnohé jevy, jakými jsou například kůrovcová kalamita, snížení výnosu v zemědělství nebo nedostatek vody ve vodních tocích. Důsledky sucha mají jak negativní ekonomický, tak ekologický rozměr.

Z těchto důvodů je nutné hledat východiska, která pomůžou krajině jako celku čelit suchu. Jednou z možností je hledat ekotypy rostlin a stromů, které jsou schopné přežívat období s nedostatkem vody lépe než jiné. Tyto ekotypy mohou být upřednostněny ve výsadbě, aby se krajina stala vůči suchu odolnější.

Cílem této práce je zhodnotit, zda pomocí laboratorní a obrazové spektroskopie můžeme sledovat reakci borovice lesní (*Pinus sylvestris*) na stres z nedostatku vody a zda tyto metody dokážou porovnat reakci na stres v případě rozdílných ekotypů borovice. Práce využívá jednak laboratorní hyperspektrální data. S jejich využitím byl hodnocen a porovnáván vliv sucha na dva rozdílné ekotypy borovice. V laboratorním experimentu byly semenáčky dvou ekotypů rozděleny do tří skupin s rozdílnou mírou závlahy. V časovém horizontu tří měsíců byla měřena jejich spektrální odezva spektorradiometrem. V této práci je navržen nový způsob, jakým lze nedestruktivně měřit semenáčky borovice lesní. Vztah mezi spektrálními daty, obsahem vody a obsahem chlorofylu v jehlicích byl zkoumán lineárním regresním modelem. Signifikance rozdílů mezi ekotypy a skupinami s různou závlahou byla určena pomocí smíšeného statistického modelu a analýzy rozptylu. K hodnocení rozdílů byly využity také vegetační indexy a klasifikátory řízené pixelové klasifikace.

Dále byla analyzována obrazová hyperspektrální data ze tří semenných sadů v ČR nasnímaná v létě roku 2020 hyperspektrální kamerou Headwall NANO-Hyperspec umístěnou na dronu UAS DJI Matrice 600Pro. Cílem bylo zjistit, zda s pomocí těchto dat lze odlišit rozdílné ekotypy borovice lesní. V práci je navržen způsob, jak spektrálně charakterizovat jednotlivé stromy, které jsou v obrazu reprezentovány mnoha pixely. Rozdílnost mezi jednotlivými ekotypy a sady byla zkoumána pomocí analýzy rozptylu a klasifikátory řízené pixelové klasifikace.

V literatuře téma rozlišení ekotypů borovice lesní pomocí spektroskopických metod není častým předmětem výzkumu. Výsledky této práce mohou napovědět, jak lze ekotypy rozlišit a zda na přesnost rozlišení má vliv jejich reakce na nedostatek vody. Práce byla zpracovávána v návaznosti na mezinárodní projekt INTER-ACTION s názvem *Využití genetické variability hyperspektrální odrazivosti ekotypů borovice lesní pro selekci jedinců odolných vůči suchu*.

Cíle

1. Navrhnout vhodnou nedestruktivní metodu pro měření semenáčků jehličnanů spektrometrem (s ohledem na použité metody v literatuře a přesné výsledky – snaha získat čistá spektra jehlic).
2. Zjistit, zda se v laboratorních spektrech semenáčků borovice projeví vodní stres různé intenzity a zda se bude reakce borovic lišit dle ekotypu.
3. Zjistit, zda je možné v obrazových a laboratorních spektrech rozlišit rozdílné ekotypy borovice lesní.

Hypotézy:

1. Ve spektrech semenáčků borovice bude možné detekovat vodní stres.
2. Z laboratorních a obrazových spekter borovice lesní bude možné rozeznat různé ekotypy.

2 Literární rešerše a úvod do problematiky

Přehled literatury lze rozdělit na dvě části. První část se věnuje spektroskopii v obecné rovině. Je zde zdokumentováno, na jakých principech je spektroskopie založena a jakými způsoby se odlišuje spektroskopie laboratorní od obrazové. Dále je uveden přehled metod, které byly doposud použity pro detekci sucha a odlišení ekotypů, a výsledky, k nimž autoři dospěli.

Druhá část rešerše je věnována nutným biologickým podkladům použitým pro práci. Jedná se o stručný popis různých ekotypů borovice lesní (*Pinus sylvestris*) v České republice a způsob reakce borovice lesní na stres z nedostatku vody.

2.1 Spektroskopie

Spektroskopie je fyzikální obor, který se zabývá vlastnostmi spekter elektromagnetického záření a jejich změnami po interakci se vzorkem (Prosser 1989). Spektroskopie se dělí dle způsobu měření na dva podobory. První možností je měření spektrometrem. V tomto případě je měřena energie záření pro určitou vlnovou délku v elektromagnetickém spektru. Energie může být měřena přes celé spektrum, nebo jen určité množství vlnových délek (Schneider a Young 1997). Výsledkem jsou jednotlivé spektrální křivky měřených objektů. Tento postup je nazýván laboratorní spektroskopií. Druhou možností jsou měření obrazovými senzory, které jsou upevněné na snímácím stroji (satelitu, letadle, dronu). Výsledkem tohoto snímání je obraz, ve kterém každý pixel reprezentuje jednu spektrální křivku. Snímání těmito senzory je označováno jako obrazová spektroskopie (Albrechtová, Kupková, Campbell 2017). Spektroskopické metody tvoří základ pro pasivní družicové systémy, které spadají do dálkového průzkumu Země (FIS 2020).

2.1.1 Laboratorní spektroskopie

Laboratorní spektroskopie je obor zaměřený na měření energie záření ve vybraných vlnových délkách elektromagnetického spektra (Schneider a Young 1997). Výsledkem měření je jednorozměrná funkce odrazivosti a vlnové délky nazývaná spektrální křivkou. Spektrální křivka je základem pro další zpracování naměřených dat. Odrazivost se zpravidla měří v oblasti mezi 400 a 2500 nm. V nižších a vyšších vlnových délkách, než je zmíněné rozmezí, je elektromagnetické záření silně absorbováno atmosférou (molekulami O₃, H₂O a CO₂), což by způsobilo příliš vysoký šum v měření (Kolář, Halounová, Pavelka 1997).

Každý povrch má odlišnou spektrální křivku. U rostlin mají na její vzhled vliv fyziologické a biochemické vlastnosti rostlin. Absorpce záření chlorofylem *a* a *b* způsobuje nízkou odrazivost v červené oblasti spektra (s minimem v 645 nm) a v modré oblasti s minimem v 445 nm (Gates et al. 1965). V modré oblasti absorbují záření také další pigmenty rostlin jako karotenoidy. Oblast blízkého

infračerveného spektra (750–1350 nm) není silně ovlivněná pigmenty, nýbrž strukturou listů a jehlic (Slaton et al. 2001). Vzhled spektrální křivky v této oblasti je silně ovlivněn poměrem mezibuněčných prostor v mezofylu vyplněných vzduchem (Knipling 1970). Obsah vody v rostlině má vliv na nižší odrazivost ve středním infračerveném spektru, tedy v rozmezí 1300 až 2500 nm (Gates et al. 1965, Tucker 1978). Důležitou oblastí spektrální křivky je prudký nárůst odrazivosti mezi červeným spektrem a blízkým infračerveným. Pozice inflexního bodu této narůstající křivky je označována jako „red edge“. Čím vyšší absorpce chlorofyly, tím širší je rozsah vlnových délek, ve kterých se projevuje nižší odrazivost, a tím je pozice „red edge“ ve vyšších vlnových délkách (Dawson a Curran 1998).

Měření probíhá spektrometrem, kterým se pomocí optického kabelu měří spektrum daného povrchu. Snímání může být provedeno buďto přímo optickým kabelem (Chávez et al. 2013), kontaktní sondou (Neuwirthová et al. 2017), nebo za pomoci integrační sféry (Zhang et al. 2008).

Měření optickým kabelem samotným se využívá v případech, kdy je vhodné mít větší zorné pole. To je vhodné při měření větších nehomogenních ploch, např. lučních porostech nebo částech stromů (Albrechtová, Kupková, Campbell 2017, Kim et al. 2018). Kontaktní sonda je přístroj, který má vlastní vnitřní zdroj záření a lze s ním provádět dotykové měření (Cavender-Bares et al. 2016). To je využíváno pro měření listů a homogenních povrchů. Touto metodou lze měřit pouze odrazivost, nikoliv propustnost povrchu. Výhodou je vyšší rychlost měření a zpracování dat oproti integrační sféře (Neuwirthová et al. 2017). Integrační sféra je dalším prostředkem, kterým lze měřit odrazivost a propustnost listů a jehlic (Zhang et al. 2008). Vnitřek integrační sféry je vytvořen z materiálu s vysokou odrazivostí, což způsobuje odražení elektromagnetického záření rovnoměrně do všech směrů (Albrechtová, Kupková, Campbell 2017). Integrační sféra má několik vstupních otvorů, ke kterým jsou připevňovány měřené vzorky, nebo zdroj záření (Stimson et al. 2005, Zhang et al. 2008). Jelikož spektrometr měří bezrozměrné celočíselné hodnoty (tzv. DN–hodnoty), je nutné při jakémkoli ze zmíněných způsobů měření měřit také bílou referenci. Jedná se o panel, který odráží přes 90 % elektromagnetického záření ve všech vlnových délkách (Jung et al. 2012). Teprve z poměru DN–hodnoty vzorku a bílé reference lze vypočítat odrazivost vzorku.

Skutečnost, že se v laboratorní spektroskopii měří pouze jedno elektromagnetické spektrum, přináší obtíže při měření nehomogenních povrchů. Vzhledem k zaměření této práce je vhodné se zaměřit na způsoby a problémy spektroskopického měření jehlic a úzkých listů. Hlavním problémem při měření jehlic je větší zorné pole optického kabelu, než je jedna jehlice. Tím do měřeného signálu vstupuje pozadí, nikoliv pouze odražené světlo z jehlice. Další otázkou při měření jehlic je, jak naložit se strukturou jehlic. Jehlice kvůli své geometrii a stavbě odrážejí světlo různě dle svého natočení.

Chávez et al. (2013) měřili ve svém článku semenáčky stromu *Prosopis tamarugo* v laboratorních podmínkách přímo optickým kabelem, který byl umístěn 15 cm nad semenáčkem. Autoři tvrdí, že do zorného pole optického kabelu podkladový povrch nezasahuje a je tak měřeno pouze spektrum rostliny.

Stejné podmínky při měření byly zajištěny tím, že se semenáčky ani spektrometr během pokusu nepřemísťovaly a vždy byla měřena stejná část rostliny.

Kim et al. (2018) měřili borovice Thunbergovy (*Pinus thunbergii*) v semenných sadech při různém napadení hádátka borového. Borovice snímali optickým kabelem vždy pětkrát na vrcholu stromku a v jejich prostřední části. Přestože se autoři snažili měřit vždy ve stejnou denní dobu, byl šum v datech velice vysoký a musel být odstraněn. Vysoký šum v datech autoři však přisuzují rozdílným podmínkám v počasí, které se během měření velice měřilo (vlhkost vzduchu, vítr a oblačnost). Šum, který mohl vniknout geometrií jehlic, nebo pozadím borovice, autoři nediskutují.

Van Aardt a Wynne (2001) se zabývali spektroskopickým měřením v semenném sadu, kde měřili různé jehličnany a porovnávali možnosti jejich spektrálního odlišení. Autoři pro zajištění stejných podmínek měřili pouze při stejných povětrnostních podmínkách – bezoblačné počasí a stálá vlhkost vzduchu. Vzorky měřili pouze v horní třetině stromu na sluncem osvětlené straně. V tomto článku se autoři snažili snížit šum v datech vzniklý geometrií a pozadím jehlic. Pro snížení vlivu pozadí použili konvexní čočku, které zmenšila zorné pole. Tím pádem bylo možné měřit pouze skupinu jehlic, která měla být analyzována. Pro snížení vlivu geometrie použili autoři průměrování deseti měření na strom a v každé skupině jehličnanů měřili 50 jedinců.

Moran et al. (2000) zkoumali vliv množství dusíku v půdě na Engelmanův smrk (*Picea engelmannii*) a analyzovali jeho spektrální projev. Z každého semenáčku odebrali dostatečné množství jehlic tak, aby pokrylo celý povrch v kulaté misce, která měla černé dno. Jehlice byly uměle osvětlené halogenem. Pro každý vzorek byla měřena stejná plocha jehlic. Autoři nemuseli brát v potaz vliv pozadí, jelikož vrstva jehlic vždy pokrývala celé zorné pole optického kabelu.

Nedestruktivní metodu měření jehlic zvolili Sundblad et al. (2001). V pokusu autoři zkoumali vliv mrazu na semenáčky jehličnanů. Při spektrálním měření zploštili semenáček mezi dvěma skly a za semenáček umístili černé pozadí. Rostlinu následně měřili z blízkosti 10 mm, čímž optický kabel snímal velice malou plochu semenáčku. Pro snížení šumu na každém vzorku průměrovali 15 měření.

Další možností, jak měřit jehlice spektrometrem, je pomocí integrační sféry. Zhang et al. (2008) zjišťovali obsah chlorofylu z jehlic smrku černého (*Picea mariana*) pomocí hyperspektrálních dat. Pět jehlic smrku upevnili na černý nosič, který umístili pod zdroj světla. Jehlice byly umístěny mezi zdrojem světla a vnitřkem integrační sféry. Vliv natočení měřených jehliček autoři nediskutují. Stimson et al. (2005) analyzovali spektrální chování jehlic borovice jedlé (*Pinus edulis*) a jalovce (*Juniperus monosperma*) za účelem zjištění obsahu vody. Z jehlic vytvořili hustou mřížku, která byla umístěna naproti zdroji světla v integrační sféře. Pro snížení šumu byl každý vzorek měřen 10krát. Zároveň autoři měřili procentuální pokrytí mřížky jehlicemi. U borovice docílili pokrytí 94 %, u jalovce pouze 62 % povrchu. Korelace mezi spektry a laboratorně měřeným obsahem vody byla u borovice ($R^2 = 0,71$) vyšší než u jalovce ($R^2 = 0,50$), což autoři přisuzují nižšímu pokrytí mřížky jehlicemi jalovce.

Z literatury vyplývá, že v laboratorní spektroskopii může mít na kvalitu měření vliv velké množství faktorů. Při měření mimo laboratoř, například v semenných sadech, má na kvalitu měření největší vliv počasí. Oblačnost, vlhkost vzduchu a vítr mají na šum v datech daleko větší vliv než geometrie jehlic a pozadí (Kim et al. 2018, Van Aardt a Wynne 2001). Vliv počasí je v laboratorních podmínkách (umělé osvětlení, konstantní vlhkost vzduchu) minimalizován. Při měření v laboratoři má na kvalitu spektrálního měření vliv pozadí jehlic a procento měřeného pozadí (Stimson et al. 2005). Této skutečnosti se lze vyhnout buďto snížením zorného pole tak, aby byla snímána pouze rostlina (Sundblad et al. 2001, Van Aardt a Wynne 2001), nebo nahuštěním jehlic tak, aby nebylo pozadí vidět (Chávez et al. 2013, Moran et al. 2000). Vliv geometrie a natočení jehlic je v praxi snižován vysokým množstvím naměřených vzorků a jejich průměrováním. (Sundblad et al. 2001, Van Aardt a Wynne 2001)

2.1.2 Obrazová spektroskopie

Obrazovou spektroskopií se ve většině literatury rozumí sběr spektrálních dat pomocí hyperspektrálních skenerů (Delaney et al. 2016, Madritch et al. 2014). V každém pixelu snímku je uchováno právě jedno elektromagnetické spektrum. Hyperspektrální snímek je souborem mnoha monochromatických snímků, kdy každý reprezentuje jedno spektrální pásmo (Adão et al. 2017).

Hyperspektrální snímky lze charakterizovat jejich spektrálním a prostorovým rozlišením (Stuart et al. 2019). Dle zhodnocení mnoha různých hyperspektrálních skenerů od Vorovenciiho (2009) a Adãa et al. (2017) se počet spektrálních pásem pohybuje mezi 100 a 600, v závislosti na typu skeneru. Tato pásma jsou většinou umístěna v rozmezí 400–2500 nm, tedy od viditelného elektromagnetického záření po střední infračervené. Některé senzory mají navíc několik pásem v oblasti termálního infračerveného záření (mezi 8000–14000 nm). Spektrální rozlišení (šířka jednoho pásma) se pohybuje od 2 do 12 nm. Jakou velikost reprezentuje jeden pixel v hyperspektrálním snímku silně závisí na výšce, ze které je snímán. V případě zavěšení skeneru přímo nad rostliny může být velikost pixelu v řádech milimetrů (Behman et al. 2014), v případě snímání z dronu v řádech centimetrů (Natesan et al. 2018). Při umístění snímače na letadlo se pohybuje velikost pixelu v řádech desítek centimetrů až metrů (Madritch et al. 2014).

Vzhledem k vlastnostem obrazových dat je častým jevem, že měřený povrch není reprezentovaný právě jedním pixelem, což vede ke dvěma otázkám. Jednak může být měřený povrch rozdělen do více pixelů. Nastává otázka, jak sledovaný povrch charakterizovat jednou spektrální křivkou. Druhou komplikací může být, že sledovaný povrch není ani na jednom pixelu – nachází se v několika pixelech pouze částečně a nemáme čistý pixel. Jak je s těmito problémy v praxi nakládáno, se liší.

Případ mnoha pixelů pro jednu rostlinu řešili Lien et al. (2019) tak, že ručně nakreslili obrys rostliny, ze kterého byly vybrány pixely pro další analýzy. Kreslit obrys rostliny pro každý případ je však časově velice náročné, proto někteří autoři volí poloautomatická řešení. Behmann et al. (2014) a

Buddenbaum et al. (2015) měli ve svém pokusu homogenní pozadí rostlin. Tím pádem nejprve klasifikovali snímek jednoduchým algoritmem *k-means*, pomocí kterého dokázali lokalizovat třídu pozadí. Tu odstranili a zbylé pixely použili k další analýze. Při měření mimo laboratorní prostředí je složité zajistit homogenní pozadí. Van Aardt a Wynne (2007) proto určili jako spektrální charakteristiku stromu okolních 9 pixelů kolem jeho GPS pozice při prostorovém rozlišení 3,4 m. V článku od Donga et al. (2020) byla extrahována spektrální informace ze stromů snímaných dronem v jablečném sadu. Nejprve byla provedena 3D rekonstrukce ze dvourozměrného obrazu pomocí metody Structure From Motion a byly vytvořeny digitální model terénu a digitální výškový model. Pomocí výškových filtrů z modelů bylo zjištěno, kde jsou lokalizované stromy a z pixelů ležících v dané oblasti byla extrahována spektrální informace. Zhang et al. (2020) detekovali z hyperspektrálních dat koruny stromů napadených housenkou *Dendrolimus tabulaeformis*. Na detekci korun použili pixelovou klasifikaci SVM, která byla kombinovaná s filtrem zachovávajícím hrany (EPF). Určení koruny stromu proběhlo s přesností 93 %.

Nedostatek čistých pixelů je častěji řešen u družicových dat, která mají horší prostorové rozlišení než snímky z hyperspektrálních skenerů nesených letadlem nebo dronem. V dálkovém průzkumu Země se pro zvýšení rozlišení snímku nejčastěji používají různé metody pansharpeningu. Tyto metody spočívají v tom, že se použije monochromatický snímek s vysokým rozlišením, pomocí kterého se zvýší rozlišení multispektrálního obrazu s nižším prostorovým rozlišením (Xiangchao et al. 2019). Metod, kterými lze docílit zvýšení prostorového rozlišení pomocí pansharpeningu, je velké množství. Jejich efektivitu a využitelnost diskutují např. Kahraman a Erturk (2018). Někteří autoři se s horším prostorovým rozlišením vypořádávají odlišně. Například Madritch et al. (2014) znali GPS pozice sledovaných stromů. Pro analýzu dat vybírali pixely tak, aby v pixelu bylo alespoň 5 GPS pozic stromů a 60 % z nich mělo stejný genotyp.

2.1.3 Metody pro vyhodnocení spektroskopických dat

Nejjednodušší metodou, kterou lze vyhodnotit spektrometrická data, je porovnání spektrálních křivek navzájem. To je možné učinit vícero způsoby. Jednou z metod je SAM (Spectral Angle Mapper). U této metody představuje rozdíl mezi dvěma spektry úhel mezi vektory x a y , které reprezentují dané měření v n -rozměrném prostoru (přičemž n je počet měřených vlnových délek). V praxi se tato metoda používá především k řízení klasifikaci, kdy je vzorek přiřazen ke skupině, ke které je úhel / rozdíl nejmenší (Bertels et al. 2021). Míru rozdílnosti mezi dvěma spektry lze kvantifikovat i pomocí Jeffries-Matusita distance (Dabboor et al. 2014) nebo Bhattacharyya distance (Xun a Wang 2015).

Pro stanovení míry odlišnosti mezi spektry lze využít statistické testy. U statistických testů se předpokládá, že je hledán rozdíl mezi dvěma nebo více skupinami, kdy u každé z nich bylo naměřeno několik vzorků. Jejich výhodou je, že berou v potaz variabilitu v datech. Pomocí statistických testů lze určit, jak statisticky významný rozdíl mezi skupinami je. Často používaný je párový t-test, u kterého se

testuje, zda je rozdíl středních hodnot rozdělení dvou skupin roven předem určenému číslu (Kim 2015). Další metodou je analýza rozptylu (ANOVA). Pomocí této metody lze určit, zda má na náhodnou veličinu (například ekotyp) statisticky významný vliv hodnota některé měřené proměnné – například odrazivosti v určité vlnové délce (Stahle a Wold 1989, Lhotáková et al. 2021). Pro zpracování dat, která jsou měřena v časových řadách jsou využívány lineární smíšené modely. Užitečnost těchto modelů k analýze časových řad je daná tím, že nemusejí být pozorované náhodné veličiny na sobě nezávislé a nemusejí mít normální rozdělení (na rozdíl od již zmíněné analýzy rozptylu) (Bonansea et al. 2015).

Další metody zpracování spektrometrických dat jsou založené na úpravě či transformaci naměřených hodnot. Jednou z metod úpravy spektrálních hodnot jsou vegetační indexy. Cílem vegetačních indexů je zmenšit rozsah hodnot odrazivosti na jednu, která popisuje určitou vlastnost rostliny či sledovaného povrchu. V praxi se jedná o vzorec, pomocí kterého je z více hodnot odrazivosti v určitých vlnových délkách různými matematickými operacemi vytvořena jedna hodnota (Jackson a Huete 1991). Vegetačních indexů je velké množství a vlnové délky, ze kterých jsou počítané, jsou vybírány podle parametrů vegetace, které jsou sledovány. Mezi indexy citlivé na obsah vody v rostlině patří například Normalised Difference Water Index (NDWI), Water Index (WI) nebo Moisture Stress Index (MSI) (Zhang a Zhou 2019). K určení obsahu chlorofylu jsou vhodné indexy jako Normalised Difference Vegetation Index (NDVI), Modified Chlorophyll Absorption Ratio Index (MCARI) nebo Transformed Chlorophyll Absorption Ratio Index (TCARI) (Wu et al. 2008). Obsah karotenoidů lze odhadnout například pomocí indexů Carotenoid Reflectance Index (CRI) nebo Chappel Index (Chap) (Fassnacht et al. 2015). Na vlnové délky, ze kterých jsou počítané existující vegetační indexy, mohou mít vliv i jiné faktory než jen sledované parametry rostliny. Vegetační index proto v některých případech nemusí korelovat se sledovaným fyziologickým parametrem. V literatuře je proto běžné se setkat s opačným postupem, tedy nejprve nalézt vlnové délky, které korelují se sledovanou veličinou. Z těchto vlnových délek lze spočítat nový vegetační index, který může být na určitou vlastnost rostliny citlivější než existující vegetační indexy (např. Maccioni et al. 2001).

Transformační metodou, jejímž cílem je normalizovat a zvýraznit některé vlastnosti spektrální křivky kolem jejích absorpčních pásem, je odstranění kontinua (Kokaly et al. 2003). Odstranění kontinua umožňuje kvantifikovat některé parametry v absorpčním pásmu. Nejčastěji používané parametry jsou plocha pod linií kontinua označovaná jako Area Under Curve (AUC) a maximální hloubka pásma – Maximum Band Depth (MBD). Parametry počítané po odstranění kontinua bývají řazeny mezi vegetační indexy (Chávez et al. 2013, Malenovský et al. 2013).

Jelikož jsou často hodnoty odrazivosti v určitých vlnových délkách navzájem korelované, mohou být jejich hodnoty transformovány pomocí analýzy hlavních komponent (PCA). Jedná se o metodu, která používá lineární vektorovou transformaci ke snížení počtu navzájem korelovaných proměnných na menší počet nekorelovaných proměnných, které se nazývají hlavní komponenty. Jednotky několika

počátečních hlavních komponent můžou obsahovat až 99 % celkové variance v datech. Ke každé vlnové délce je určena hodnota *eigenvalue*. Jedná se o míru variance v tomto pásmu. Čím vyšší tato hodnota je, tím vyšší je variabilita mezi vzorky v této vlnové délce (Chatterjee et al. 2019, Danusievicius et al. 2014).

Důležitou součástí zpracování spektroskopických dat je způsob hledání vztahů mezi spektry a dalšími parametry vegetace. K tomuto účelu jsou používány regresní modely. Nejjednodušším regresním modelem je lineární regrese. V tomto případě je vztah mezi závislou a nezávislou veličinou určen přímkou. Vztah mezi veličinami může být charakterizován také polynomem nebo jinými funkcemi. Velikost variability a úspěšnost regrese je charakterizována koeficientem determinace R^2 (Albrechtová, Kupková, Campbell 2017). Při mnohonásobné krokové regresi jsou pozorovaná data prokládána lineární kombinací nezávislých veličin (například hodnotami odrazivosti v určité vlnové délce). Výsledkem této regrese je skupina vlnových délek, ke kterým je určen vzorec pro jejich lineární kombinaci, která má s pozorovanými daty nejvyšší korelační koeficient. Prakticky se jedná o součet hodnot odrazivosti v určitých vlnových délkách, přičemž každá má různou váhu (Kokaly a Clark 1999). PLS (Partial Least Square) regrese je často používána pro datové sady, kde je malé množství vzorků a jejich hodnoty mají vysoký podíl šumu. PLS regrese kombinuje prvky z analýzy hlavních komponent a mnohonásobné krokové regrese. Cílem je predikovat a analyzovat závislé veličiny na základě datové sady nezávislých veličin. Přesnost regrese je určena rozdílem mezi predikovanou hodnotou a skutečnou hodnotou (Abdi 2003).

Významnou součástí Dálkového průzkumu země a spektroskopie jsou klasifikační metody. Klasifikace je proces, při kterém je prvkům přiřazován určitý informační význam. V průběhu klasifikace jsou radiometrické hodnoty nahrazovány hodnotou reprezentující určitou klasifikační třídu. Nutnou součástí klasifikačního procesu je klasifikátor, tedy soubor pravidel, podle kterých jsou prvky zařazeny do stanovených tříd (Dobrovolný 1998). Klasifikační algoritmy lze rozdělit na objektovou a pixelovou. Jelikož v této práci není využit objektový přístup, jsou zde popsány pouze metody řízené a neřízené pixelové klasifikace.

Při neřízené pixelové klasifikaci uživatel použije algoritmus, který vyhledá shluky příznakových vektorů podle předem určeného počtu. Tyto shluky reprezentují jednotlivé třídy. Uživatel následně musí identifikovat, o jaké třídy se jedná (Schowengerdt 2007). K nejznámějším algoritmům neřízené klasifikace patří metoda k-means. V tomto případě je na počátku klasifikace určen střed předem určeného počtu tříd v n-rozměrném prostoru (kdy n je počet vlnových délek). Každý vzorek je přiřazen k té třídě, k jejíž středu je jeho euklidovská vzdálenost nejmenší. Často používaná je také metoda ISODATA. V tomto případě jsou určeny středy shluků náhodně. Každý prvek je přiřazen ke třídě, ke které je jeho euklidovská vzdálenost nejmenší. Následně se znovu vypočítá střed shluku jako střední hodnota prvků, které do shluku byly přiřazeny. Tento algoritmus se opakuje do té doby, než se hodnoty středů

shluků již nemění (Kolář, Halounová, Pavelka 1997). Do této skupiny algoritmů patří také další metody, jakými jsou například GMM-based clustering nebo mean shift clustering (Yang et al. 2010).

V případě řízené pixelové klasifikace je nutné mít pro každou třídu předem připravenou datovou sadu, pomocí které je klasifikátor natrénován. Další prvky jsou zařazovány do tříd podle toho, jak byl klasifikátor natrénován. Proto je velice důležité, aby trénovací množiny byly homogenním vzorkem třídy, ale zároveň v nich byla obsažena variabilita vyskytující se v dané třídě (Schowengerdt 2007).

Nejjednodušší skupinou řízených klasifikátorů jsou klasifikátory nejbližšího souseda (kth-nearest neighbour). Prvek je zařazen do třídy, do které patří většina jeho sousedů (z trénovacích množin). Sousedi musí ležet od prvku do určité vzdálenosti v n-rozměrném prostoru. Klasifikátory v této skupině se odlišují tím, jak je nastavena vzdálenost od prvku nebo jaký počet sousedů je brán v potaz. Podle nastavení těchto parametrů jsou klasifikátory nazývány například Fine KNN, Cubic KNN nebo Medium KNN (Kiang 2003).

Do skupiny řízených klasifikací patří diskriminační analýzy. Z trénovacích množin je vygenerována diskriminační funkce, která roztrídí pozorovaná data do určeného počtu skupin tak, aby byla minimalizována chybovost přiřazení prvků. Diskriminačních analýz je velké množství, například lineární diskriminační analýza (LDA), nebo vícerozměrná diskriminační analýza (MDA) (Kiang 2003).

Další metodou řízené klasifikace je metoda Support Vector Machine (SVM). Při této klasifikaci je n-rozměrný prostor prokládán pomocnými funkcemi tak, aby tvořily hranice tříd. Typy této klasifikace se odlišují podle proložené funkce. Tato metoda může být výpočetně velice náročná, pokud nejsou využity lineární funkce, ale například n-rozměrné polynomy určující hranice tříd (Oommen et al. 2021).

Metoda maximální věrohodnosti (Maximum Likelihood) a Naive Bayes jsou klasifikačními algoritmy, které jsou založené na statistickém přístupu. Shluky prvků v n-rozměrném prostoru se často překrývají a je proto složité zařadit sporné prvky. U metody maximální věrohodnosti je předpokládáno, že má trénovací sada normální rozdělení. Každá třída je reprezentována n-rozměrným histogramem, který určuje pravděpodobnost, se kterou prvek patří do dané třídy. Klasifikovaný prvek leží v několika histogramech a je zařazen do třídy dle histogramu s nejvyšší hodnotou pravděpodobnosti (Bolstad a Lillesand 1991). Rozšířením metody maximální věrohodnosti je bayesovský klasifikátor. Při této metodě lze přikládat pravděpodobnostem příslušnosti k určité třídě různé váhy. Nejčastěji se váhy přikládají podle procentuálního zastoupení třídy v obraze nebo trénovací sadě. Tímto způsobem lze zvýšit pravděpodobnost přiřazení ke třídě, která je zastoupená častěji. Algoritmus upravuje metodu maximální věrohodnosti o dodání tzv. a priori pravděpodobnosti (Dobrovolný 1998).

Významnou roli v klasifikačních metodách hrají v současné době metody založené na hlubokém učení. K těmto metodám například patří neuronové sítě (ANN) nebo fuzzy systémy (Kolář, Halounová, Pavelka 1997, Chen et al. 2018).

2.2 Borovice lesní

Borovice lesní (*Pinus sylvestris*) je jehličnatým stromem patřícím k čeledi borovicovitých (*Pinaceae*) a k rodu *Pinus*. Tento rod je nejrozšířenějším v rámci čeledi, je popsáno cca 100 až 120 druhů borovic. Borovice lesní se vyskytuje téměř po celé Evropě a Asii. Hojně zastoupená je také v České republice, kde je druhým nejrozšířenějším stromem a její podíl v lesích tvoří kolem 18 % (Kaňák 2011).

Důvodem častého vysazování borovice lesní je její odolnost. Dokáže dobře čelit silným mrazům, vysokým teplotám a přímým slunečním paprskům. Proti požárům je chráněná silnou borkou a je odolnější vůči imisím než ostatní stromy (Kaňák 2011, Kaňák 1993). Důležitým faktorem je také dobrá hospodářská využitelnost. Borovicové dřevo je lehké, trvanlivé a odolné, což vede k širokému využití v nábytkářství, truhlářství a stavebnictví (Matovič 1992).

V České republice se také nachází autochtonní borovice lesní, a to v malém zastoupení na reliktních stanovištích, kde přečkala poslední dobu ledovou. Jedná se například o balvanité svahy, sutě, písky, nebo některá rašeliniště (Kaňák 2011).

2.2.1 Ekotypy borovice lesní a semenné sady v ČR

Borovice lesní se v České republice dělí na dva ekotypy. Prvním ekotypem je borovice pahorkatní (chlumní). Tento druh borovice se vyskytuje ve vegetačním stupni 1 až 4, je citlivý na sněhové polomy, mráz a ledovku. Je odolný vůči suchu. Má hrubou borku, která je na spodní části kmenu. Koruna je rozložitější a brzy se zaobluje. Druhým ekotypem je borovice horská (náhorní). Tento ekotyp se vyskytuje ve vegetačních stupních 5 až 7. Dobře snáší horské klima, je však citlivý na dlouhotrvající sucho. Kmen je rovný a ve vyšších polohách svalcovitý. Borka je tmavá a šupinatá, dosahuje v této formě až ke koruně. Koruna je úzká a delší. Hustota jehlic je různá, jsou relativně krátké. Jelikož je borovice lesní světlomilná, jsou oba ekotypy velice citlivé na zastínění. Pahorkatinný ekotyp nejlépe vyrůstá na nezastíněných stanovištích na minerální půdě. Náhorní ekotyp může vyrůstat i pod řídkým porostem (Šindelář 1991, Kaňák 2011).

Šlechtění borovice lesní v ČR má historii sahající na počátek 20. století, první semenné sady byly založeny v 70. letech 20. století. Semenné sady jsou výsadbami naroubovaných stromů, které splňují určitá kritéria. Cílem semenných sadů je zajištění kvalitního osiva a také uchování geofundu ohrožených populací dřevin. Pro správné fungování semenného sadu je nutné testování jednotlivých klonů vybraných na základě ekotypu, aby se zjistilo, zda jejich potomstva odpovídají kritériím výběru a zda jsou tato kritéria výběru geneticky podmíněná (Kaňák et al. 2009).

Valná většina semenných sadů v ČR jsou klonové sady. Skládají se z roubovanců (ramet) klonů vybraných podle jejich fenotypových vlastností. Kritéria výběru se liší dle šlechtitelského záměru. K vlastnostem, ke kterým se při výběru přihlíží, patří hlavně morfologické parametry jako například

výška, tloušťka a tvárnost kmene. Ramety pocházejícího z jednoho stromu tvoří jeden genotyp. Genotyp může být v semenném sadu reprezentován více rametami. Pokud je sad přímo založen z těchto roubovanců, jedná se o sad první generace. Následně je nutné ověřit, zda jsou morfologické parametry geneticky podmíněné. K tomuto účelu se využívají semena ze sadu první generace a je založena testovací výsadba. Z testovací výsadby jsou vybrány semenáčky, u kterých se prokáže, že jejich vlastnosti jsou geneticky podmíněné. Z jejich semen lze založit semenný sad druhé generace. Čím vyšší je generace sadu, tím hodnotnější je z ekonomického hlediska (Korecký 2012, Kaňák 2011).

Všechny semenné sady borovic v ČR jsou první generace. Celkově se zde nachází 37 semenných sadů na 125 hektarech půdy a 24 z nich je spravováno Lesy ČR (Korecký 2012).

2.2.2 Indikátory stresu z nedostatku vody

Vliv sucha byl u borovic pozorován na obsahu fotosyntetických pigmentů. Manes et al. (2001) pozorovali borovice halepské (*Pinus halepensis*) v laboratorních podmínkách, kde byly vystaveny nedostatku vody. Byl pozorován signifikantní úbytek chlorofylu *a* a *b* a také karotenoidů. Reakce na sucho byla na obsahu pigmentů pozorovatelná od 18. dne po začátku experimentu. Podobné závěry vyvodili také Conroy et al. (1986), v jejichž článku byla pozorována reakce borovice monteyerské (*Pinus raidata*) na nedostatek vody a zvýšený obsah CO₂. Obsah chlorofylu *a* a *b* klesal po celou dobu osmitýdenního pokusu. Semerci et al. (2017) pozorovali obsah fotosyntetických pigmentů u borovice lesní (*Pinus sylvestris*) sužované nedostatkem vody v závislosti na její provenienci. V rámci pokusu byl zjištěn pokles obsahu chlorofylu *a* a *b*, stejně tak jako karotenoidů. Obsah pigmentů se signifikantně odlišoval dle provenience.

Dalším indikátorem stresu může být obsah prolinu, aminokyseliny, která je součástí proteinů v rostlině a také působí proti osmotickému stresu. Gao et al. (2009) sledovali obsah prolinu u tří druhů borovic (*Pinus densata*, *Pinus yunnanensis*, *Pinus tabulaeformis*) při snížené závlivce. Po 28 dnech sucha byl pozorován nárůst obsahu prolinu v jehlicích o 143 až 210 % dle druhu borovice. Deligoz a Gur (2015) sledovali obsah prolinu u borovice pinie (*Pinus pinea*) po stresu z nedostatku vody. Již po 14 dnech byl u rostlin vystaveným stresu obsah prolinu signifikantně vyšší. Obsah rozpustných cukrů v jehlicích je dle autorů dalším faktorem závislým na dostupnosti vody. U dostatečně zalévaných borovic byl detekován signifikantně vyšší obsah cukrů než u stresovaných jedinců (Deligoz a Gur 2015).

Vodní stres ovlivňuje výměnu plynů v rostlině v důsledku uzavření průduchů. Snížení výměny plynů u stresovaných jedinců borovic pozorovali Manes et al. (2001). U těchto jedinců se kvůli zadržení vody snížila transpirace až blízko k 0 mol H₂O m⁻² s⁻¹. Cregg a Zhang (2001) analyzovali fotosyntetickou aktivitu a transpiraci různých ekotypů borovice lesní (*Pinus sylvestris*). Oba sledované parametry se začaly rapidně snižovat od prvního snížení závlivky u pozorovaných semenáčků. Kolem 19. dne pokusu se již transpirace pohybovala kolem 0 mol m⁻² s⁻¹ a ekotyp na tuto veličinu neměl vliv.

Nedostatek vody má za důsledek horší růstové schopnosti rostliny. De Diego et al. (2015) sledovali biometrické a fyziologické parametry u dvouletých semenáčků borovice montereyské (*Pinus radiata*). Stresované rostliny měly po dobu experimentu nižší přírůstek do výšky a také nižší obvodový přírůstek. Obdobné výsledky pozorovali Deligoz a Gur (2015). Stresované semenáčky borovice měly nižší přírůstek ve výšce než kontrola. V tomto experimentu byly také analyzovány kořeny semenáčků. Váha kořenů byla po experimentu u stresovaných jedinců signifikantně nižší než u dostatečně zalévaných jedinců. Signifikantní rozdíly v růstových parametrech mezi ošetřeními potvrzují také Cregg a Zhang (2001).

V neposlední řadě lze nedostatek vody indikovat změřením obsahu vody v rostlině nebo půdním substrátu. Jedním z parametrů je vodní potenciál jehlic, který vyjadřuje stav vody v pletivech rostliny (závislou na koncentraci solutů, tlaku a pozici v gravitačním poli) oproti čisté vodě za atmosférického tlaku. S vodním stresem se vodní potenciál v pletivech rostlin většinou snižuje. Snižující se vodní potenciál u stresovaných borovic pozorovali například Manes et al. (2001) nebo De Diego et al. (2015). Cregg a Zhang (2001) stanovili obsah vody v rostlině pomocí rozdílu váhy jehlic po a před vysušením v troubě. Stresované rostliny měly signifikantně nižší obsah vody v jehlicích než kontrola. Gao et al. (2009) stejným způsobem určovali obsah vody v půdě a zjistili rapidní pokles obsahu vody v půdě u stresovaných rostlin.

V této kapitole o indikátorech stresu z nedostatku vody jsou ve stručnosti popsány pouze ty, které jsou nejčastěji zmiňované v literatuře. V odborné literatuře však lze nalézt spoustu dalších důsledků, které sucho u borovic může způsobit. Vliv může mít sucho mimo jiné na fluorescenci rostlin (Conroy et al. 1986), obsahy iontů (Mg^{2+} , Na^+ , Fe^{2+}) (Semerci et al. 2017), obsah peroxidu vodíku, antioxidačních enzymů nebo kyseliny askorbové (Gao et al. 2009).

2.3 Spektroskopické metody pro detekci sucha

Vlivy sucha na fyziologický stav rostlin a jejich spektrální projev jsou předmětem mnohých publikací a důležitou součástí aplikovaného výzkumu ve spektroskopii a dálkovém průzkumu Země. Praktickou roli hraje nedestruktivní spektrální detekce reakcí rostlin na sucho v zemědělství (Behmann et al. 2014).

V již zmíněném článku od Cháveze et al. (2013) byl zkoumán vztah mezi spektrálními příznaky a naměřenými hodnotami obsahu chlorofylu, karotenoidů a procentuálním obsahem vody v listu. K tomuto účelu byly pěstovány v laboratorních podmínkách semenáčky Naditce tamarugo (*Prosopis tamarugo*) a po dobu 15 dní byly bez zálivky. V tomto období byly rostliny snímány spektrometrem 13krát za den. Následně autoři ze spektrálních dat spočítali velké množství vegetačních indexů (např. NDVI, RVI, WI) a indexů založených na kontinuu křivky odrazivosti. Z dat byl vytvořen model radiačního přenosu Soil-Leaf-Canopy. Změny v reflektanci po úbytku vody byly na celé spektrální křivce. Se změnami

obsahu vody koreloval nejvíce Water Index (poměr 900 a 970 nm), jeho přesnost se však zmenšovala se zvyšujícím se obsahem vody. Při vyšším obsahu vody v listech se jako přesnější indikátor projevila plocha pod grafem spektrální křivky mezi 910 a 1070 nm po odstranění kontinua.

Lien et al. (2019) sledovali vliv stresu z nedostatku vody u huseníčku rolního (*Arabidopsis thaliana*) na jeho spektrální charakteristiku. Rostlinu měřili v laboratorních podmínkách po dobu sedmi dní hyperspektrálním skenerem. Část rostlin nebyla zalévána. Ze spekter byly vypočítány poměrové indexy $NDSI(i,j)$, kdy byly kombinovány normalizované poměry dvou spekter i,j pro všechna měřená pásma a hledána nejcitlivější z nich na změny způsobené suchem. Rozsah spekter mezi 700 a 900 nm (především pozice „red edge“ a pomezí blízkého infračerveného záření) byl shledán jako nejcitlivější pro oddělení skupin rozdělených dle míry zálivky, jelikož zde byly nejnižší p-hodnoty použitého t-testu. Použitý skener NANO Hyperspec má rozsah měření mezi 400-1000 nm, tudíž nebyl zkoumán vliv sucha na oblast středního infračerveného záření.

Využití odrazivosti v blízkém a středním infračerveném záření pro monitorování sucha u buku lesního (*Fagus sylvatica*) popisují Buddenbaum et al. (2015). V rámci experimentu sledovali pět týdnů sedmnáct semenáčků, přičemž polovina byla po tuto dobu bez zálivky. Měření probíhalo spektrometrem, dále byl měřen obsah chlorofylu a procentuální obsah vody v listech. Zpracování dat proběhlo pomocí částečné regrese (PLS regrese). Při této regresi se předpokládá mezi vstupními parametry lineární vztah a pomocí metody nejmenších čtverců se určuje, jak silná tato korelace je. Autoři zjistili, že pro odhad obsahu chlorofylu ze spektrálních dat postačují vlnové délky z blízkého infračerveného spektra. Naopak predikce procentuálního obsahu vody byla robustnější při kombinaci spekter z oblastí blízkého a středního infračerveného záření.

Blízko tématu této práce je článek Stimsona et al. (2005), ve kterém autoři zkoumali možnosti spektroskopie pro určení obsahu vody v jehlicích borovice jedlé (*Pinus edulis*) a jalovce (*Juniperus monosperma*). Celkově byly analyzovány vzorky z 19 borovic a 9 jalovců. Vzorky byly vybírány tak, aby byly zastoupeny různé míry sucha stromů, a tím pádem různý obsah vody v jehlicích. Spektra jehlic byla měřena v integrační sféře (viz kapitola 2.1.1), jako parametry k porovnání autoři měřili procentuální obsah vody v jehlicích a vodní potenciál. Ze spektrálních dat autoři vypočítali množství vegetačních indexů (NDVI, RVI, NDWI, AI) a pozici „red edge“. Nejvyšší korelaci s procentuálním obsahem vody u borovice jedlé vykazoval index NDVI ($R^2 = 0,71$), následován NDWI ($R^2 = 0,68$). Vyšší citlivost indexu NDVI vysvětlují autoři nárůstem suchých sloučenin uhlíku jako celulózy a ligninu, což má na spektrální křivku větší vliv než obsah vody v jehlicích. Snižující se obsah vody měl vliv na index NDWI, který se počítá z absorpčních pásem vody. Tento index je však dle autorů více citlivý na anatomii jehlic a jejich biochemii, proto měl nižší hodnoty korelačního koeficientu. U jalovce byly zjištěny podstatně nižší hodnoty korelace mezi procentuálním obsahem vody a spektrálními daty, což autoři přisuzují nízké hustotě jehlic v mřížce měřené v integrační sféře.

Z literatury vyplývá výrazná citlivost na stres způsobený nedostatkem vody v oblasti „red edge“ a navazující oblasti blízkého infračerveného záření (700 - 900 nm). Jako robustní odhad pro obsah vody se jeví index NDVI, počítaný právě z těchto vlnových délek (Lien et al. 2019, Stimson et al. 2005). Citlivá na obsah vody jsou dále pásma v blízkém infračerveném spektru (900 – 1070 nm), středním infračerveném spektru a z nich odvozené indexy NDWI a WI (Chávez et al. 2013, Stimson et al. 2005). Tato část spektrální křivky je ovlivněna samotným obsahem vody v rostlině (Gates et al. 1965). Druhotné projevy stresu ze sucha jako suchá celulóza a lignin mají na spektrální křivku silnější vliv, než samotný úbytek vody (Stimson et al. 2005). Přesto je pro robustnější odhad obsahu vody vhodné kombinovat jak spektra z blízkého, tak ze středního infračerveného spektra (Buddenbaum et al. 2015).

2.4 Odlišení ekotypů a genotypů pomocí spektroskopie

Otázce, zda lze odlišit různé genotypy pomocí spektroskopie, se věnovali v případové studii Madritch et al. (2014), kteří popisovali vliv genotypu topolu osikovitého (*Populus tremuloides*) na jeho spektrální projev. V rámci experimentu byly měřeny různé fyziologické vlastnosti 700 volně rostoucích topolů ve dvou lokalitách USA, ke kterým byla naměřena spektrální data. Genomická DNA byla určena ze sušených listů topolů a ze vzorků autoři stanovili 79 různých genotypů. Pro porovnání genotypů byla provedena jak chemická analýza listů (např. obsah dusíku, taninu, ligninu), tak půdy pod stromem (např. obsah amonia, a dusičnanů). Letecky naměřená obrazová hyperspektrální data ze senzoru AVIRIS byla získána od společnosti NASA. Pro porovnání naměřených dat byla použita korelační kanonická analýza a to jak pro nalezení vztahů mezi fyziologickými parametry, tak se spektrálními daty. Pro nalezení vztahu mezi genotypem a spektry byl využit Mantelův test. Autoři byli schopni rozeznat různé genotypy z hyperspektrálních dat s přesností 80 %. Odvození genotypu ze spekter bylo přesnější než z fyziologických vlastností topolů. To autoři zdůvodňují tím, že spektrální data jsou citlivá na mnohem větší množství fyziologických parametrů rostliny, než které autoři měřili v chemické analýze listů a půdy.

Možnostem odlišení různých druhů borovice pomocí spektrálních dat se věnovali ve dvou článcích van Aardt a Wynne (2001 a 2007). Ve starším článku autoři porovnávali spektra šesti stromů, z toho tří borovic (*Pinus taeda*, *Pinus virginiana*, *Pinus echinata*). Stromy měřili v terénu pomocí spektrometru a naměřili celkově 291 vzorků. Pro účely tohoto článku autoři neměřili další fyziologické vlastnosti rostlin a zaměřili se pouze na statistické zpracování spektrálních dat. Pro snížení dimezionality dat použili částečnou diskriminační analýzu, čímž z původních 2000 spektrálních pásem vybrali nejrozumnějších 5 až 20 pásem. Pro zjištění spektrální odlišnosti podobně jako Madritch et al. (2014) využili kanonické korelační analýzy. Z analýzy vyplývá, že pro spektrální odlišení druhů jsou vhodná pásma viditelného a blízkého infračerveného spektra (350–1700 nm). Naopak vliv druhu stromu se méně manifestoval v odrazivosti středního infračerveného spektra (1700-2500 nm). Pomocí křížové validace stanovili autoři schopnost rozlišit různé druhy borovic s přesností 83 %. V roce 2007 pokračovali

autoři dalším pokusem, kdy se zaměřují pouze na zmíněné tři druhy borovic. Odlišný byl také způsob měření spekter. Spektrometr nahradili obrazovým hyperspektrálním skenerem AVIRIS. Celkově nasníмали 200 borovic různých druhů. Z hyperspektrálních snímků autoři opět vybrali maximálně 10 spektrálních pásem pomocí krokové diskriminační analýzy, aby se snížil zpracováváný objem dat. Pro zjištění spektrální odlišnosti mezi druhy borovice byla použita kanonická korelační analýza. Výsledky potvrdily závěry z předchozího článku. Nejcitlivější pásma pro odlišení druhů borovic byla z viditelného a blízkého infračerveného spektra. Přesnost rozlišení druhů borovice narostla na 85 %. Toto navýšení autoři vysvětlují průměrováním 9 pixelů pro každý strom, což mohlo snížit šum v datech.

Danusevicius et al. (2014) zkoumali možnosti rozlišení proveniencí borovice lesní (*Pinus sylvestris*) dle jejich původu pomocí spektroskopie. Ze semenného sadu v Litvě autoři vybrali 5 borovic o výšce alespoň 15 m. Každá byla původem z jiného regionu bývalého Sovětského Svazu. V průběhu května až září 2012 bylo provedeno 7 měření. Při každém měření bylo odebráno 80 vzorků jehlic, které byly následně měřeny hyperspektrální kamerou. Na hyperspektrální data byla aplikována analýza hlavních komponent (PCA) pro snížení objemu dat. Dále autoři použili diskriminační analýzu (metoda neřízené klasifikace), pomocí které roztřídili spektrální data ze vzorků do skupin dle očekávaných původů borovic. Přesnost klasifikace následně hodnotili pomocí křížové validace. Přesnost klasifikace silně závisela na datu, kdy byly vzorky odebrány. Nejvyšší přesnost klasifikace byla 11. června 2012 (89 %). Naopak vzorky z 5. května 2012 byly klasifikovány s přesností pouze 55 %. Zjištění vlivu fenologických cyklů na přesnost klasifikace je největším přínosem tohoto článku. Na počátku června některým borovicím začaly růst nové jehlice. Posunutými fenologickými cykly různých fenotypů se v tomto období jehlice borovic nejvíce odlišovaly jak obsahem chlorofylu, tak strukturou buněk. Vlnové délky kolem 680 nm a vlnové délky vyššího blízkého infračerveného spektra (pásma citlivá na obsah chlorofylu a obsah vody) jsou dle autorů nejvhodnější k detekci rozdílů mezi fenotypy.

Z článků lze vyčíst, že čím geneticky vzdálenější druhy stromů jsou, tím snadnější je zaznamenat rozdíly mezi nimi ve spektrálním projevu (van Aardt a Wynne 2007, Madritch et al. 2014). Velký vliv na to, zda lze různé druhy odlišit, má období, kdy jsou spektra pořízena. Pokud jsou fenologické cykly v rámci různých druhů posunuté, může být snadnější je rozeznat v období, které se vyznačuje velkými změnami ve spektrálním projevu - například růstem nových jehlic (Danusevicius et al. 2014).

3 Data a metodika

3.1 Obrazová hyperspektrální data

3.1.1 Zájmové území

Obrazová hyperspektrální data byla pořízena ve třech semenných sadech v ČR. První semenný sad je umístěn na Děčínském sněžníku. Jedná se o semenný sad, kde jsou vysazeny stromy náhorního ekotypu borovice. Dalšími semennými sady jsou sad u Plas v Plzeňském kraji (Doubrava) a sad Holičky. V těchto semenných sadech jsou pěstovány borovice pahorkatinného ekotypu. Základní informace o semenných sadech jsou uvedeny v tabulce 1.



Obrázek 1: Přehled semenných sadů (vlastní zpracování), podkladová mapa z www.mapy.cz

Semenný sad	Doubrava	Holičky	Děčín
lesní správa LČR	Plasy	Třeboň	Děčín
rok založení	1980	1981	2003
počet klonů	86	108	78
rozloha (ha)	6,48	5,35	1,33
souřadnice (WGS 84)	49,9087617 N 13,4427394 E	49,0166106 N 14,8247583 E	50,8191364 N 14,1172131 E

přírodní lesní oblast	6 - Západočeská pahorkatina	15b - Jihočeské pánve, část třeboňská pánev	19 - Lužická pískovcová vrchovina
lesní vegetační stupeň	2 - bukodubový	3 - dubobukový	5 - jedlobukový a 6 - smrkobukový
nadmořská výška (m. n. m.)	385	430	465

Tabulka 1: Základní údaje o semenných sadech. Vytvořeno podle Provozníka (2021).

3.1.2 Data hyperspektrální kamery Nano-Hyperspec®

Obrazová data byla pořízena hyperspektrální kamerou Nano-Hyperspec®, která byla umístěna na hexahoptéře UAS DJI Matrice 600 Pro. Hyperspektrální kamera snímá v rozsahu 400–1000 nm. V těchto vlnových délkách je měřeno celkem 270 spektrálních pásem, rozstup mezi pásmy činí 2,24 nm. Jedná se o pushbroom-skener a šířka záběru je 640 pixelů. Měřený pás může být dlouhý dle zájmového území a je limitován velikostí ukládacího prostoru o 480 GB (Headwall 2021).



Obrázek 2: Hyperspektrální kamera Nano-Hyperspec® (Headwall 2021)

Obrazová data byla pořízena na počátku srpna 2020. Sady v Děčíně a Doubravě byly nasnímány s jednodenním odstupem. Hyperspektrální data ze sadu v Holičkách byla naměřena o 11 dní později. Všechna měření proběhla v dopoledních hodinách mezi 9:30 a 12:15.

Semenný sad	Datum	Čas
Děčín	6.8.2020	9:30 – 10:30
Doubrava	5.8.2020	9:45 – 12:15
Holičky	17.8.2020	9:45 – 12:00

Tabulka 2: Datum a čas pořízení hyperspektrálních dat


Každý semenný sad byl při měření rozdělen do několika pásů. Počet pásů se pohyboval mezi 10 až 18 na jeden semenný sad. Pásky byly rozvrženy tak, aby každý strom byl alespoň na jednom pásu obsažen celý. Překryv pásů činil kolem 30 %. Díky nízké výšce letu bylo prostorové rozlišení pixelu 3 x 3 cm.

Data byla radiometricky korigována v programu SpectralView - Hyperspec v3.1.0. Naměřené DN – hodnoty byly převedeny na radianci. K tomuto účelu byla využita černá reference, která byla získána tím způsobem, že byl nasnímán snímek se zakrytým objektivem kamery. K přepočtu radiance na reflektanci byl využit bílý koberec s 56 % odrazivostí. Radiance naměřeného koberce byla uložena jako bílá reference. S pomocí hodnot bílé reference byly přepočítány všechny ostatní pixelové hodnoty z radiance na reflektanci. Podrobně popisují radiometrickou korekci hyperspektrálních dat z kamery Nano-Hyperspec® Červená et al. 2020.

3.1.3 Extrakce spekter požadovaných jedinců


Ze změřených dat bylo nutné vybrat požadované jedince a vypočítat jejich spektrální charakteristiku pro další analýzu dat. Spektrální charakteristika každého stromu sestávala z průměrné hodnoty, mediánu a směrodatné odchylky odrazivosti v každé měřené vlnové délce.

V prvním kroku byly nalezeny pixely patřící k určitému stromu a bylo k nim přiřazeno ID stromu. Střed stromu byl ručně označen pomocí bodu a jako atribut mu bylo přiřazeno číslo stromu. Jelikož byl každý sad rozdělen do více pásů, byl přidán také atribut, ze kterého pásu sadu mají být pixely pro daný strom extrahovány. Každý strom byl alespoň na jednom pásu nasnímán celý. Z bodové vrstvy byl v programu QGIS vytvořen buffer kolem bodu o velikosti 0,75 m. V případě, že v polygonu byly obsaženy také pixely mimo korunu strom, byl manuálně zmenšen tak, aby obsahoval pouze pixely stromu.



Obrázek 3: Část polygonů, ze kterých byly extrahovány pixely stromů

V dalším kroku byly vyřazeny pixely, které měly moc vysokou, nebo nízkou odrazivost. Tento krok byl přidán, aby byl snížen šum v datech. K nalezení pixelů, které měly moc vysokou nebo nízkou odrazivost byla použita neřízená klasifikace k-means. Aby byly třídy vytvořeny na všech pásech stejně, musela být provedena klasifikace na všech pásech ze všech sadů zároveň. Klasifikace proběhla za pomoci knihovny *sklearn* v Pythonu 3.7. Z klasifikovaných osmi tříd byly vybrány tři třídy, které reprezentovaly pixely s příliš nízkou a příliš vysokou odrazivostí. Dvě třídy zastupovaly pixely s příliš nízkou reflektancí. Jednalo se především o místa, kde borovice vrhaly stín. V jedné třídě byly obsaženy pixely s příliš vysokými radiometrickými hodnotami. Práhy odrazivosti klasifikovaných skupin, které byly odstraněny, se lišily pro každou vlnovou délku. Například pro oblast 850 nm byly pro odstranění klasifikovány pixely s odrazivostí nižší než 0,15 a vyšší než 0,7. Na obrázku 4 jsou odstraněné pixely označeny červenou a oranžovou barvou.



Obrázek 4: Klasifikace k-means

Z polygonu reprezentující strom byly nejprve vybrány hodnoty reflektance pixelů, které nebyly v klasifikaci vyhodnoceny jako nežádoucí. Z těchto hodnot byla následně vypočítána pro každou vlnovou délku průměrná hodnota, směrodatná odchylka a medián. Tyto tři hodnoty a identifikační číslo daného stromu byly exportovány do textového souboru pro další zpracování. Výpočet a uložení dat bylo provedeno s pomocí Pythonu 3.7.

3.1.4 Analýza obrazových spektrálních dat

Spektrální křivky jednotlivých stromů byly rozděleny dle ekotypu (náhorního nebo pahorkatinného). Zda se tyto ekotypy liší bylo zjištěno analýzou rozptylu (ANOVA). Jedná se o metodu, kterou lze stanovit statistickou významnost odlišnosti určitých skupin. Statistická významnost je kvantifikována tzv. p-hodnotou. Pokud je p-hodnota vyšší než 0,05, nejsou skupiny statisticky významně odlišné. Naopak při nižších hodnotách než 0,05 je odlišnost těchto skupin statisticky významná. Analýza

rozptylu byla provedena pro každou vlnovou délku. Byly určeny vlnové délky, ve kterých se ekotypy borovice lesní statisticky významně odlišují. Zpracování proběhlo ve statistickém programu Matlab.

Indikátorem spektrální odlišnosti určitých skupin jsou také přesnosti trénování klasifikací. Byly natrénovány celkem čtyři klasifikátory a přesnost jejich natrénování byla vyhodnocena křížovou validací. Klasifikátory byly vybrány tak, aby zastupovaly různé skupiny klasifikátorů (například statistický přístup, diskriminační analýzy nebo jednoduché klasifikace). Natrénované byly následující klasifikátory: Naive Bayes, Linear Discriminant Analysis (LDA), Support Vector Machine (SVM) a Fine k-th Nearest Neighbour (Fine KNN).

Přesnost natrénování klasifikace byla určena křížovou validací. V tomto případě byla vždy odebrána spektrální křivka jednoho stromu, klasifikátor byl natrénován a vynechaná spektrální křivka byla klasifikována k určité třídě. Přesnost byla určena procentem vynechaných spekter stromů, které byly zařazeny do správné třídy. Obvykle bývá při křížové validaci vynecháváno větší množství prvků najednou. U těchto dat byl zvolen pouze jeden vynechávaný prvek kvůli relativně nízkému počtu trénovacích vzorků (73 až 107) pro každou klasifikovanou skupinu. Natrénování klasifikátorů proběhlo v aplikaci Classification Learner, která je součástí programu Matlab.

3.2 Laboratorní spektra

3.2.1 Průběh měření

Laboratorní experiment probíhal od dubna do července roku 2021 ve skleníku Katedry experimentální biologie rostlin PŘF UK. Ze semenných sadů bylo zajištěno 100 semenáčků dvouletých borovic, přičemž byl z poloviny zastoupen náhorní ekotyp a z poloviny pahorkatinný. Borovice pocházely z odlišných sadů, než ze kterých byla pořízena obrazová hyperspektrální data. Semenáčky náhorního ekotypu sestávaly z potomstev semenného sadu na Přimdě. Pahorkatinná borovice pocházela z náhodných rodičovských stromů z Písecka.

Semenáčky byly rozděleny do tří skupin dle intenzity zálivky. Jedna skupina byla zalévána dostatečně (skupina „kontrola“ v tabulce 3), u druhé skupiny byl navozen mírný stres (skupina „střední sucho“ v tabulce 3) z nedostatku vody a třetí skupina borovic byla zalévána tak, aby měly borovice silný nedostatek vody (skupina „silné sucho“ v tabulce 3). Zbýlých 18 jedinců bylo také rozděleno do skupin dle míry stresu a ekotypu (3 semenáčky pro každý ekotyp a každou kategorii sucha), byly však využity k měření vlhkosti půdy. Jelikož půdní sondy pro měření vlhkosti nemohly být během experimentu vyjmuty, nebyla na těchto borovicích měřena spektrální data.

Ekotyp	Míra stresu	Počet jedinců
náhorní	silné sucho	14
náhorní	střední sucho	14
náhorní	kontrola	13
pahorkatinný	silné sucho	14
pahorkatinný	střední sucho	14
pahorkatinný	kontrola	13

Tabulka 3: Počet měřených jedinců dle ekotypu a míry stresu


Datum	Čas	Objem zálivky (ml)		
		Kontrola	Střední sucho	Silné sucho
15.4.	17:30	200	0	0
20.4.	16:30	0	100	0
22.4.	17:00	100	100	100
29.4.	18:30	200	100	50
30.4.	13:30	0	0	100
4.5.	14:15	150	75	0
7.5.	14:15	50	25	0
10.5.	15:15	75	50	25
14.5.	16:45	75	50	25
18.5.	17:15	75	25	0
21.5.	12:15	75	50	25
25.5.	19:45	50	25	0
3.6.	21:00	75	50	0
8.6.	16:00	50	25	0
9.6.	16:00	75	50	0
11.6.	16:30	75	25	25
16.6.	16:00	100	50	25
18.6.	18:30	150	75	25
22.6.	1:00	100	75	50
REGENERACE				
25.6.	16:45	200	200	200
2.7.	12:00	100	100	100
6.7.	5:45	100	100	100
8.7.	15:45	100	100	100
11.7.	10:00	50	50	50
14.7.	14:00	200	200	200

Tabulka 4: Objem, čas a datum zálivky dle skupin ošetření

Semenáčky borovice byly do skleníku převezeny na konci března 2021. Po instalaci do skleníku byly podrobeny 14–denní aklimaci na nové prostředí. V polovině dubna byly borovice rozděleny do skupin s rozdílnou zálivkou a intenzita zálivky byla též kontrolována pomocí sond umístěných v květináčích neměřených semenáčků. Zálivka byla v případě semenáčků v kontrolní skupině 75-200 ml za týden, ve skupině středního sucha 25-100 ml za týden a ve skupině silného sucha 0-100 ml za týden. Míra zálivky byla vycházela z článku Pearsona et al. 2013. Podrobný rozpis objemu zálivky je uveden v tabulce 4.

Od 22. 4. byla každý týden měřena spektra semenáčků. Měření probíhalo každý čtvrtek mezi 8. a 14. hodinou. Vždy byla měřena spektra borovic pomocí spektrometru ASD FieldSpec 4 Wide-Res. Měřen byl též obsah chlorofylu přístrojem Chlorofyl Content Meter (CCM-300). Vlhkostní sondy byly v půdním substrátu po celou dobu měření a obsah vody v půdě byl zaznamenáván jednou za hodinu.

Od 24.6. byla ukončena fáze rozdílné zálivky a všechny skupiny semenáčků borovice byly zalévány dostatečně a stejně (viz tabulka 4). Byla zahájena fáze regenerace. Po jednom týdnu a třech týdnech regenerace byla provedena poslední dvě měření. Časová osa s daty měření je na obrázku 5.



Obrázek 5: Časová osa laboratorního experimentu

Na počátku a experimentu (22.4.) a po týdnu regenerace (30.6.) byly provedeny dva odběry jehlic pro laboratorní stanovení obsahu chlorofylu a vody v jehlicích. Stanovení chlorofylu proběhlo pomocí extrakce pigmentů z pletiva a spektrofotometrického měření. Obsah vody v jehlicích byl zjištěn vážením jehlic před a po jejich vysušení.

3.2.2 Způsob měření a přístroje


Spektrální data byla pořízena spektrometrem ASD FieldSpec 4 Wide-Res. Přístroj měří radianci v rozmezí od 350 do 2500 nm. V oblasti od 350 do 1000 nm je zaznamenávána v intervalech po 3 nm pomocí křemíkové mřížky. Od 1001 do 2500 nm je radiance měřena po 30 nm fotodiodami z inda, galia a arsenu (InGaAs diody) (Potůčková et al. 2016).

Pro výpočet odrazivosti byl při každém měření snímán spektralon, tedy bílý kalibrovaný panel, jehož odrazivost je přes 99 % ve všech vlnových délkách. Odrazivost vzorku pro danou vlnovou délku byla získána vzorcem:

$$\text{odrazivost vzorku} = \frac{\text{radiance vzorku}}{\text{radiance spektralonu}}$$

Výsledná spektrální křivka byla převzorkována na odrazivost po intervalech 1 nm a uložena do textového souboru pro další zpracování.

Pro měření semenáčků borovic spektroradiometrem byla navržena speciální soustava. Diagram soustavy je vyobrazen na obrázku 6, na obrázku 7 je fotografie samotného měření. Semenáčky borovic byly umísťovány do černého květináče na hever (umožňoval nastavení stejné výšky u měření pro různě velké semenáčky). Vzdálenost středu heveru a borovice od optického kabelu byla 24 cm. Při zorném poli optického kabelu 25° činil poloměr kruhu, který vstupoval do měření v této vzdálenosti od optického kabelu, přibližně 5,3 cm. Z toho důvodu byl hever vždy zvednut do takové výšky, aby vzdálenost místa,



Obrázek 6: Diagram soustavy pro měření spektrálních dat

kam mířil optický kabel, byla od horního konce borovice 5,3 cm. Výška heveru byla pro každou rostlinu zdokumentována při prvním měření a zůstala pro každé následující měření konstantní. Tím pádem nevstupovaly do měření mladé vyrůstající výhonky, které začaly po začátku měření růst na horním konci semenáčků. Měřena byla pouze část borovice narostlá za minulý rok.

Borovice byly při měření osvětleny speciálními světly od firmy ASD. Světla vyzařovala záření se stejnou intenzitou ve všech vlnových délkách v rozmezí 350–2500 nm. Vzdálenost od semenáčku byla u každého světla 50 cm. Úhel mezi světly byl 60°. Zbytek místnosti byl kompletně zatemněn, aby jiné záření neovlivnilo měření. Hever s borovicí byl umístěn ve skříni, jejíž vnitřní strana byla natřena černou barvou značky Nextel®, která maximálně pohlcuje dopadající záření.

V každém z měřících dnů byla kromě spekter borovic měřena také radiance bílé reference. Bílá reference byla snímána buďto po 12 semenáčcích borovic, nebo pokud byla poslední bílá reference měřena před delší dobou než 10 minut. Dále bylo v průběhu každého měřícího dne čtyřikrát změřeno a uloženo spektrum černého pozadí, které bylo následně využito na úpravu spektrální křivky popsané v kapitole 3.2.3. Ke každému semenáčku borovice byla zároveň pořízena fotografie, pomocí které byl spočítán poměr černého pozadí a samotné borovice v zorném poli optického kabelu. Výsledné měření bílé reference bylo průměrováno ze 100 měření. Výsledné spektrum vzorků borovice bylo průměrováno ze 25 měření.



Obrázek 7: Fotografie z měření semenáčku borovice

Borovicím, na kterých byla měřena spektra, byl změřen obsah chlorofylu pomocí přístroje Chlorophyll Content Meter 300 (CCM-300) od společnosti Opti-Sciences. Tento přístroj měří poměr emitované fluorescence ve vlnových délkách 735 a 700 nm. Z této hodnoty byl s pomocí kalibračního vzorce spočítán obsah chlorofylu na plochu ($\mu\text{g}/\text{cm}^2$). Kalibrační křivka byla vytvořena z laboratorně naměřeného chlorofylu v létě 2020. Mezi hodnotami emitované fluorescence a hodnotami laboratorně stanoveného chlorofylu byla provedena lineární regrese. Z regresní křivky byl získán vzorec, kterým byly přepočítány hodnoty emitované fluorescence na hodnoty chlorofylu na plochu ($\mu\text{g}/\text{cm}^2$). Výhodou přístroje CCM-300 je, že je přímo navržen pro měření jehlic a úzkých listů a že je schopen měřit velký rozsah obsahu chlorofylu (od 41 do $675 \text{ mg}/\text{m}^2$) (Opti-Sciences 200?).

Obsah vody v půdě byl měřen s pomocí půdních sond WaterScout SM 100. Sondy jsou složeny ze dvou elektrod, které fungují jako kondenzátor. Půda, do které jsou vloženy, slouží jako dielektrikum. Oscilátor s frekvencí 80 MHz pohání kondenzátor a signál odpovídající relativní permitivitě půdy je


převeden jako výstupní signál. Čím vyšší je obsah vody v půdě, tím vyšší má půda relativní permitivitu (Spectrum Technologies 2021). Sondy byly na celou dobu experimentu vloženy do květináčů 18 semenáčků z různých ekotypů a různě zalévaných skupin, u nichž nebyla měřena spektra. Sondy do přijímací stanice odesílaly naměřené hodnoty jednou za hodinu. Měřené hodnoty byly převedeny na procentuální obsah vody pomocí gravimetrické kalibrace.

Ke stanovení obsahu chlorofylu v odebraných jehlicích bylo třeba několik kroků. Nejprve byly změřeny hmotnost a povrch jehlic. Následně byly jehlice rozdrčeny v třence a zality acetonem. Na acetonovém extraktu byly změřeny spektrofotometrem hodnoty absorbance ve vlnových délkách $\lambda=663$ nm, $\lambda=646$ nm a $\lambda=470$ nm. Z hodnot absorbance byla rovnicemi získána hodnota koncentrace chlorofylu v roztoku. Ta byla následně vztažena k hmotnosti a ploše jehlic. Obsah vody v jehlicích byl spočítán rozdílem mezi čerstvou hmotností jehlice a hmotností jehlice po 10denním vysušení v troubě.

3.2.3 Úprava spekter s pomocí fotografií semenáčků

Každý semenáček borovice měl odlišnou hustotu jehlic, strukturu a náklon. Významně se lišil poměr vstupujícího signálu z borovice a z černého pozadí. Tyto skutečnosti vedly k tomu, že spektrální křivky pro jednotlivé měřené borovice byly velice rozdílné. Čím více pozadí bylo v zorném poli optického kabelu, tím nižší byly naměřené radiometrické hodnoty ve všech pásmech. Z toho důvodu bylo nutné upravit hodnoty tak, aby odpovídaly spektrální křivce samotné borovice a vliv černého pozadí byl eliminován.

K tomuto účelu byl každý semenáček fotografován mobilním telefonem. Před začátkem měření byl vyfocen štít, jehož střed určoval, kam mířil optický kabel (obrázek 8). Na štítu bylo umístěno pravítko. Z fotografie štítu byly odečteny hodnoty pixelu z místa, kam byl namířen optický kabel. Bylo určeno kolik pixelů na fotografii představuje 1 cm. Semenáčky borovice a štít byly 24 cm vzdálené od optického



Obrázek 8: Fotografie štítu s pravítkem a místem, kam míří optický kabel.

kabelu. Při zorném poli optického kabelu o 25° vstupoval do měření v této vzdálenosti kruh o poloměru 5,3 cm. Na základě těchto informací bylo možné přesně určit, z jaké části fotografie vstupoval signál do optického kabelu.

Následně bylo na fotografii nutné odlišit pixely černého pozadí od pixelů borovice. K tomuto účelu byla natrénována časově a výpočetně nenáročná řízená pixelová klasifikace k-th Nearest Neighbour (použita například v Meng et al. 2007). Jedná se o klasifikaci, při které je pixel zařazen do té třídy, do které patří pixel z trénovacího souboru dat, ke kterému je jeho euklidovská vzdálenost nejnižší. Z pěti fotografií borovic byl vytvořen trénovací soubor dat. V souboru byly hodnoty z celkem 126150 pixelů, přičemž byly trénovány dvě skupiny – pixely borovice a pixely černého pozadí.

Na fotografii každé borovice byla provedena řízená klasifikace. V oblasti zorného pole spektrometru byl spočítán poměr dvou klasifikovaných tříd a tím pádem procentuální zastoupení borovice a černého pozadí v měřeném signálu.

V posledním kroku byla provedena úprava hodnot odrazivosti založená na metodě Linear Unmixing. U této metody se předpokládá, že je výsledný signál součtem hodnot odrazivosti několika ploch, přičemž jsou váhy těchto hodnot přiřazeny dle procentuálního zastoupení plochy. Vychází z následujícího vzorce:

$$I(\lambda) = C_1 * R_1(\lambda) + C_2 * R_2(\lambda)$$


Kdy $I(\lambda)$ je výsledná odrazivost v určité vlnové délce, C_1 a C_2 jsou procentuální zastoupení určitých povrchů a $R_1(\lambda)$ a $R_2(\lambda)$ jsou odrazivosti určitých povrchů v určité vlnové délce.

Pro případ tohoto experimentu lze uvažovat, že $I(\lambda)$ je odrazivost měřená optickým kabelem, C_1 procentuální zastoupení borovice v zorném poli, C_2 procentuální zastoupení černého pozadí v zorném poli, $R_1(\lambda)$ odrazivost borovice v určité vlnové délce a $R_2(\lambda)$ odrazivost černého pozadí v určité vlnové délce.

Odrzivost samotného homogenního černého pozadí byla měřena při každém měření 4 - krát. Z těchto měření byla spočítána průměrná hodnota odrazivosti černé skříně. Neznámou dle vzorce byla odrazivost samotné borovice v určité vlnové délce - $R_1(\lambda)$. Po vyjádření neznáme vznikl vzorec:

$$R_1(\lambda) = \frac{I(\lambda) - C_2 * R_2(\lambda)}{C_1}$$

S pomocí tohoto vzorce byly získány výsledné spektrální křivky jednotlivých borovic. Zmíněný postup byl implementován ve skriptu v programu Matlab. Analýza spekter byla provedena na hodnotách odrazivosti upravených touto metodou.



Obrázek 9: Část borovice v zorném poli optického kabelu s odmaskovaným pozadím.

3.2.4 Analýza laboratorních spekter

Pro zjištění míry odlišnosti mezi ekotypy a zálivkami přes celou dobu experimentu byl využit lineární smíšený model (např. Bonansea et al. 2015). Lineární smíšený model je vhodný pro data, která nemají normální rozdělení a mají více zdrojů variability. Je využíván pro data z opakovaných měření. Stejně jako u analýzy rozptylu je pro každou vlnovou délku určena p-hodnota. Při hodnotě nižší než 0,05 jsou rozdíly mezi skupinami signifikantní. Lineární smíšený model byl aplikován v programu R (4.0.3) s pomocí knihovny *nlme*. Všechny následující analýzy byly provedeny v programu Matlab.

Zda je míra odlišnosti mezi ekotypy a mezi zálivkami signifikantní v jednotlivých dnech měření, bylo určeno s pomocí analýzy rozptylu (ANOVA). Princip analýzy rozptylu byl již popsán v kapitolách 3.1.4 a 2.1.3. Analýza rozptylu byla využita pro nalezení vlnových délek, ve kterých je signifikantní rozdíl mezi ekotypy nebo mezi zálivkami.

Za účelem zjištění, zda se v n-rozměrném prostoru shlukují hodnoty odrazivosti podle ekotypů nebo podle zálivky, byla aplikována analýza hlavních komponent a byly natrénovány čtyři klasifikátory.

Analýza hlavních komponent (PCA) byla aplikována vždy na data z jednoho měřicího dne. Pro každou vlnovou délku byla určena hodnota *eigenvalue*, tedy míra variance v daném pásmu. Dále byly vytvořeny grafy zobrazující první a druhou hlavní komponentu pro zjištění, zda se ekotypy nebo zálivky shlukují, nebo jsou hodnoty první a druhé hlavní komponenty na ekotypu a zálivce nezávislé.

Další nápovědou pro to, zda lze rozlišit ekotyp nebo míru zálivky ze spektrálních dat, mohou být přesnosti natrénování klasifikací. Stejně jako u obrazových hyperspektrálních dat byly natrénovány čtyři různé klasifikátory: Naive Bayes, Linear Discriminant Analysis (LDA), Support Vector Machine (SVM) a Fine k-th Nearest Neighbour (Fine KNN) a zhodnocena přesnost jejich natrénování.

Jako indikátory obsahu chlorofylu a obsahu vody byly spočítány některé vegetační indexy. Z hodnot vegetačních indexů byly vytvořeny časové řady, které mohou vypovědět o vývoji stavu rostliny. Pro sledování obsahu chlorofylu byly spočítány indexy NDVI a TCARI/OSAVI. Vysokou míru korelace těchto dvou vegetačních indexů s obsahem chlorofylu pozorovali například Wu et al. 2008. K odhadnutí obsahu vody v rostlinách byly spočítány indexy MSI, NDWI a WBI. Korelaci těchto indexů s obsahem vody v rostlině popsali například Zhang a Zhou 2019 nebo Peñuelas et al. 1994. Indexy byly spočítány s pomocí následujících vzorců:

NDVI (Normalised Difference Vegetation Index)

$$NDVI = \frac{\rho_{900} - \rho_{670}}{\rho_{900} + \rho_{670}}$$

TCARI/OSAVI (Transformed Chlorophyll Absorption Reflektance Index / Optimised Soil Adjusted Vegetation Index)

$$TCARI/OSAVI = \frac{3 \left[(\rho_{700} + \rho_{670}) - 0.2(\rho_{700} + \rho_{550}) \left(\frac{\rho_{700}}{\rho_{670}} \right) \right]}{\left(\frac{\rho_{900} - \rho_{670}}{\rho_{900} + \rho_{670} + 0.16} \right)}$$

MSI (Moisture Stress Index)

$$MSI = \frac{\rho_{1599}}{\rho_{819}}$$

NDWI (Normalised Difference Water Index)

$$NDWI = \frac{\rho_{857} - \rho_{1241}}{\rho_{857} + \rho_{1241}}$$

WBI (Water Band Index)

$$WBI = \frac{\rho_{970}}{\rho_{900}}$$

Dále byl hledán vztah mezi spektrálními daty, obsahem chlorofylu (spočítaným z přístroje CCM-300 a také získaným laboratorní analýzou) a obsahem vody v jehlicích. K tomuto účelu byla využita lineární regrese. Při každém snímání spekter borovic byl naměřen obsah chlorofylu v rostlinách přístrojem CCM-300. Laboratorně získaný obsah chlorofylu byl stanoven ve dvou datech (22.4. a 30.6.), stejně tak jako obsah vody v jehlicích.

Lineární regrese proběhla na všech vlnových délkách, a to jak s obsahy chlorofylu, tak s obsahy vody. Byly určeny koeficienty determinace R^2 , pomocí kterých byly nalezeny vlnové délky s nejvyšší korelací s obsahem chlorofylu a obsahem vody v půdě.

Stejný postup byl aplikován na poměry pásem s cílem nalézt vegetační index, který se jeví jako nejvhodnější pro odhad obsahu vody v půdě nebo obsahu chlorofylu. Poměry všech pásem byly vypočítány s využitím vzorce:

$$Index_{i,j} = \frac{\rho_i}{\rho_j}$$


Přičemž se hodnoty i a j pohybovaly od 350 do 2500 nm. Pro snížení výpočetní náročnosti byly brány hodnoty i a j po intervalu 10 nm. Celkem byla spočítána lineární regrese s obsahem chlorofylu a obsahem vody na 46000 poměrových indexech. Lineární regrese byla také aplikována pro výše zmíněné spektrální indexy.

4 Výsledky


4.1 Analýza obrazových hyperspektrálních dat

4.1.1 Analýza rozptylu (ANOVA)

Analýza rozptylu byla provedena dvakrát. V prvním případě byly spektrální křivky stromů rozděleny dle dvou ekotypů. Jedna skupina představovala náhorní ekotyp a druhá skupina pahorkatinný. Při druhé analýze rozptylu byly spektrální křivky rozděleny dle sadů a skupiny byly tři.



Obrázek 10: Analýza rozptylu pro dva ekotypy




Obrázek 11: Analýza rozptylu pro tři semenné sady

Na obrázku 10 jsou uvedeny p-hodnoty analýzy rozptylu pro každou vlnovou délku pro dva ekotypy. Nižší p-hodnoty než 0,05 jsou ve všech vlnových délkách mimo oblast mezi 710-730 nm na přechodu mezi červeným a infračerveným zářením. Také v pásmech kolem 400 a 430 nm jsou některé vlnové délky, ve kterých se ekotypy statisticky významně neliší. Na obrázku 11 jsou zobrazeny p-hodnoty pro analýzu rozptylu, ve které byly spektrální křivky stromů zařazeny dle semenných sadů. V tomto případě jsou ve všech vlnových délkách p-hodnoty nižší než 0,05 a sady statisticky významně odlišné.


4.1.2 PCA a natrénování klasifikátorů

Z hodnot odrazivosti v 269 pásmech byla vytvořena analýza hlavních komponent za cílem zjistit, jaká je variabilita ve vlnových délkách a jak se shlukují data dle sadů a dle ekotypů.



Obrázek 12: Hodnoty EigenVectors pro PCA ze semenných sadů

Na obrázku 12 jsou zobrazeny hodnoty *eigenvectors* pro každou vlnovou délku. Tato hodnota vyjadřuje míru variability v určitém pásmu. Hodnoty *eigenvectors* byly vyrovnané v celé šíři měřených vlnových délek, pohybovaly se mezi -0,2 a 0,2. Zvýšené kladné a záporné hodnoty *eigenvectors* lze nalézt na začátku a na konci spektrální křivky. To je způsobeno vyšším podílem šumu v těchto oblastech spektra.



Obrázek 13: Plot hodnot první a druhé hlavní komponenty pro tři semenné sady

Na obrázku 13 jsou vyobrazeny hodnoty první a druhé hlavní komponenty pro všechny pozorované stromy. Barevně jsou odlišeny dle příslušnosti do určitého sadu. Z hodnot dvou hlavních komponent lze vysledovat silnou odlišnost druhé hlavní komponenty pro sad v Děčíně, ve kterém jsou vysazeny borovice náhorního ekotypu. Hodnoty druhé hlavní komponenty jsou zde až na výjimky významně vyšší než 5. U borovic pahorkatinného ekotypu v sadech Holičky a Doubrava se hodnoty první a druhé hlavní komponenty překrývají.

Natrénování klasifikátorů proběhlo pro čtyři klasifikátory (Naive Bayes, Linear Discriminant Analysis (LDA), Support Vector Machine (SVM) a Fine k-th Nearest Neighbour (Fine KNN)). Trénování proběhlo dvakrát, jednou pro dvě třídy (ekotypy) a jednou pro tři třídy (semenné sady). Přesnost natrénování byla určena křížovou validací.

V tabulce 5 jsou uvedeny přesnosti natrénování čtyř klasifikátorů. V případě tří sadů byla nejvyšší přesnost u metody Support Vector Machine (94,8 % stromů bylo zařazeno do správné třídy). Nejnížší přesnost měla metoda Naive Bayes (79,1 %). Při natrénování klasifikátorů pro dva ekotypy byla přesnost natrénování u všech klasifikátorů vyšší než u varianty pro tři sady. Nejvyšší přesnost měla metoda Linear Discriminant Analysis (99,6 %). Nejnížší přesnost měla metoda Naive Bayes (91,8 %).

	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	Fine k-th Nearest Neighbour
Přesnost natrénování (3 sady)	92,20%	79,10%	94,80%	88,40%
Přesnost natrénování (2 ekotypy)	99,60%	91,80%	95,50%	95,10%


Tabulka 5: Přesnosti natrénování klasifikátorů (semenné sady)

Celkově byly přesnosti natrénování pro obě varianty velmi vysoké, pouze dvě metody měly přesnost nižší než 90 %.

4.2 Analýza laboratorních spekter

4.2.1 Vliv úpravy spekter s pomocí fotografií semenáčků

Cílem úpravy spekter pomocí fotografií semenáčků bylo snížit variabilitu v hodnotách odrazivosti. Jelikož se hodnota odrazivosti v určitém pásmu vždy po úpravě zvýšila, zpravidla se také zvýšila průměrná hodnota a směrodatná odchylka odrazivosti všech spektrálních křivek. Vhodnou hodnotou, jak změnu variability v tomto případě zhodnotit, je variační koeficient, tedy poměr průměrné hodnoty a směrodatné odchylky.




Obrázek 14: Variační koeficient před a po úpravě hodnot odrazivosti

Na obrázku 14 je zobrazena hodnota variačního koeficientu před a po úpravě spekter pomocí fotografií borovic. Variační koeficient se ve většině vlnových délek po úpravě spekter snížil. Výjimkou jsou dvě absorpční pásma. Prvním je absorpční minimum chlorofylu s minimem na 650 nm, druhým absorpční pásmo vody s minimem 1900 nm. V těchto pásmech se variabilita zvýšila. Vyšší variační koeficient je v několika vlnových délkách na začátku a na konci spektrální křivky. V těchto pásmech může mít na variabilitu velký vliv zvýšený podíl šumu v hodnotách odrazivosti.

4.2.2 Smíšené modely


Smíšené lineární modely pracují s předpokladem, že jsou stejné vzorky měřeny opakovaně. Cílem těchto modelů je zjistit, zda se sledované skupiny liší přes celou dobu experimentu i přes variabilitu mezi měřeními. Pro účely této práce byly vytvořeny dva modely – jeden smíšený model pro ekotypy a jeden pro tři skupiny různé míry zálivky.



Obrázek 15: Smíšený statistický model - ekotypy

Na obrázku 15 je výsledek smíšeného modelu pro různé ekotypy. Statisticky významné rozdíly mezi ekotypy přes celou dobu měření jsou ve většině vlnových délek. Nízké p-hodnoty lze nalézt v absorpčních pásmech s minimy v 650, 1450 a 1900 nm. Významně se ekotypy také liší v oblasti zeleného záření kolem 550 nm, na počátku a na konci spektrální křivky a v oblasti blízkého infračerveného spektra (750–1350 nm). Naopak vyšší p-hodnoty než 0,05 lze nalézt na přechodech mezi nízkou a vysokou odrazivostí, tedy kolem 700 a 1400 nm. Dále nejsou ekotypy statisticky významně odlišné v oblastech infračerveného spektra kolem 1500–1800 nm nebo 2200–2300 nm. V některých oblastech viditelného záření (např. kolem 450 nebo 600 nm) se ekotypy také statisticky významně neliší.


Z výsledku smíšeného statistického modelu pro rozdíl mezi ošetřeními na obrázku 16 lze vyčíst, že je p-hodnota ve všech vlnových délkách vyšší než 0,05 a že se borovice dle míry zálivky přes celou dobu pokusu statisticky významně neliší.



Obrázek 16: Smíšený statistický model - rozdíl mezi mírou zálivky

4.2.3 Analýza rozptylu (ANOVA)


Analýza rozptylu byla provedena pro každé ze dvanácti měření zvlášť. Pro každý měřicí den byly vyhotoveny dvě analýzy - jedna pro zjištění rozdílů mezi ekotypy a druhá pro zjištění rozdílů mezi mírami zálivky.



Obrázek 17: ANOVA dle ekotypů 29.4.2021 (2. měření)

V druhý den měření (viz obrázek 17) se ekotypy statisticky významně lišily v absorpčních pásmech vody a chlorofylu s minimy v 700, 1450 a 1900 nm. P-hodnoty nižší než 0,05 byly také na začátku a konci spektrální křivky a oblasti mezi 1050–1200 nm. V ostatních vlnových délkách byly p-hodnoty vyšší než 0,05 a ekotypy se zde statisticky významně nelišily.

Ke konci měření, kdy již byl navozen stres z nedostatku vody, se ekotypy statisticky významně lišily v odlišných vlnových délkách. Na obrázku 18 je zobrazena ANOVA dle ekotypů pro 10. měření, tedy poslední měření před začátkem regenerace. P-hodnoty nižší než 0,05 jsou ve dvou absorpčních pásmech s minimy 700 a 1900 nm, rozsah vlnových délek s nízkými p-hodnotami v oblastech absorpčních pásem vody však klesl. Oproti 29.4. přibýly oblasti s nízkými p-hodnotami v oblasti zeleného záření (550 nm) a v blízkém infračerveném spektru (750–1300 nm).



Obrázek 18: ANOVA dle ekotypů 24.6.2021 (10. měření)


Přestože se v průběhu měření změnily vlnové délky, ve kterých se ekotypu statisticky významně lišily, byl po celou dobu experimentu počet pásem vyšší než 435 (tabulka 6). Nejnižší počet pásem s p-hodnotou nižší než 0,05 byl 22.4. a 15.7. Nejvyšší počet signifikantních pásem byl v období mezi 6.5. až 17.6. V tomto období byl počet statisticky významně odlišných pásem vyšší než 1200 z celkových 2151.

Měření	Datum	Počet pásem
1	22.dub	514
2	29.dub	890
3	06.kvě	1258
4	13.kvě	1609


5	20.kvě	1387
6	27.kvě	1372
7	03.čvn	1231
8	10.čvn	1466
9	17.čvn	1228
10	24.čvn	967
11	30.čvn	860
12	15.čvc	435

Tabulka 6: Počet spektrálních pásem, ve kterých jsou p-hodnoty pro ANOVU dle ekotypů nižší než 0,05


Analýza rozptylu dle zálivky na počátku měření (obrázek 19) poukazuje na to, že je minimum vlnových délek, kde jsou p-hodnoty nižší než 0,05. Výjimkou jsou některé vlnové délky na začátku spektrální křivky, kde je měření silněji ovlivněno šumem. Podobné hodnoty analýzy rozptylu zůstávají až do 10.6.2021. 10.6. a 17.6. narůstá počet vlnových délek, ve kterých jsou skupiny dle míry zálivky statisticky významně odlišné (viz příloha 18 a 19), a to v oblastech kolem 1450 a 1850 nm. Nejvíce vlnových délek s p-hodnotami nižšími než 0,05 lze před začátkem regenerace nalézt 24.6. (obrázek 20). V tento den jsou nízké p-hodnoty (kromě několika vlnových délek mezi 1650 a 1750) v celém úseku mezi 1400–1950 nm. Dále jsou statisticky významné rozdíly mezi zálivkami ve viditelném záření mezi 400–600 nm.



Obrázek 19: ANOVA dle míry zálivky 22.4.2021 (1. měření)



Obrázek 20: ANOVA dle míry zálivky 24.6.2021 (10. měření)



Obrázek 21: ANOVA dle míry zálivky 15.7.2021 (12. měření)

Paradoxně největší počet pásem, ve kterých se skupiny dle zálivky statisticky významně liší, byl dle analýzy rozptylu zjištěn tři týdny po začátku regenerace 15.7. (obrázek 21). V tento den se statisticky významně liší ošetření v oblastech 0-700 nm, 1100-1880 nm a 1900-2400 nm. Pouze v blízkém infračerveném záření mezi 750 a 1100 nm byl větší počet pásem, kde se skupiny dle zálivky signifikantně neliší.


Měření	Datum	Náhorní ekotyp	Pahorkatinný ekotyp	Nezávisle na ekotypu
1	22.dub	30	299	142
2	29.dub	127	353	206
3	06.kvě	1	371	272
4	13.kvě	0	355	227
5	20.kvě	7	350	198
6	27.kvě	0	350	196
7	03.čvn	0	364	158
8	10.čvn	317	480	192
9	17.čvn	433	961	524
10	24.čvn	599	950	756
11	30.čvn	36	967	698
12	15.čvc	1	1428	1720

Tabulka 7: Počet spektrálních pásem, ve kterých jsou p-hodnoty pro ANOVU dle záhlavky nižší než 0,05

V tabulce 7 je zobrazen počet spektrálních pásem (z celkových 2151), ve kterých je p-hodnota pro analýzu rozptylu dle ošetření nižší než 0,05. U náhorního ekotypu lze pozorovat nárůst pásem, ve kterých je signifikantní rozdíl mezi ošetřeními, od 10.6. Nevíce pásem se signifikantním rozdílem je 24.6. (599). Po začátku regenerace počet pásem klesá, 30.6. jsou ošetření rozdílná pouze v 36 pásmech, 15.7. pouze v jednom. U pahorkatinného ekotypu je od začátku experimentu do 3.6. signifikantní rozdíl mezi ošetřeními u 299–364 pásem. Výrazný nárůst lze pozorovat od 10.6., kdy se počet pásem zvýšil na 480. Počet pásem, ve kterých jsou rozdíly mezi ošetřeními statisticky významné, stoupá i po začátku regenerace. Jejich nejvyšší počet je 15.7., a to 1428. V případě, že se ekotyp nebere v potaz, je od počátku experimentu do 10.6. signifikantní rozdíl mezi ošetřeními u 142–272 pásem. Výrazný nárůst počtu pásem lze pozorovat od 17.6. (524) až do konce experimentu, kdy je jejich počet nejvyšší (1720).


4.2.4 PCA a Natrénování klasifikátorů

Analýza hlavních komponent byla provedena pro data ze všech měření najednou, aby pro každé měření byly hlavní komponenty vygenerovány stejně.




Obrázek 22: Hodnoty EigenVectors pro PCA z laboratorních spekter

Nejvyšší hodnoty *eigenvectors*, které jsou na obrázku 22, jsou na počátku a konci spektrální křivky. Zde je vysoká variabilita v hodnotách způsobena šumem v datech. Vysoké hodnoty *eigenvectors*




Obrázek 23: Plot hodnot první a druhé hlavní komponenty dle dvou ekotypů 22.4.2021




Obrázek 24: Plot hodnot první a druhé hlavní komponenty dle dvou ekotypů 24.6.2021

lze nalézt v oblasti viditelného záření (400-700 nm) a na přechodu *red edge* kolem 750 nm. Vysoká variabilita v datech je dále v oblasti infračerveného záření, především od 1800 nm výše.

Rozdíly mezi ekotypy lze podobně jako u obrazových dat nalézt v hodnotách druhé hlavní komponenty. Většina semenáčků náhorního ekotypu má kladné hodnoty druhé hlavní komponenty, oproti tomu má pahorkatinný ekotyp záporné hodnoty. V bodovém grafu zobrazujícím první a druhou hlavní komponentu se tvoří shluky dle ekotypů po celou dobu měření nezávisle na ošetřeních. Na obrázcích 23 a 24 jsou zobrazeny výsledky analýzy hlavních komponent pro první měření 22.4. a desáté měření 24.6.



Obrázek 25: Plot hodnot první a druhé hlavní komponenty dle míry závlivky 22.4.2021



Obrázek 26: Plot hodnot první a druhé hlavní komponenty dle míry závlivky 24.6.2021

Hodnoty první a druhé hlavní komponenty u skupin semenáčků dle závlivky (obrázky 25 a 26) jsou nezávislé na typu ošetření. Při desátém měření (24.6.) jsou převládají kladné hodnoty první hlavní komponenty u silného sucha. Více semenáčků ze skupiny silné sucho má také záporné hodnoty druhé

Měření	Datum	Linear Discriminant Analysis	Native Bayes	Support Vector Machine	Fine k-th Nearest Neighbour
1	22.dub	97,56%	64,63%	86,59%	59,76%
2	29.dub	96,34%	62,20%	85,37%	69,51%
3	06.kvě	97,56%	64,63%	89,02%	64,63%
4	13.kvě	97,56%	69,51%	87,80%	69,51%
5	20.kvě	95,12%	69,51%	85,37%	64,63%
6	27.kvě	93,90%	73,17%	86,59%	73,17%
7	03.čvn	96,34%	68,29%	89,02%	78,05%
8	10.čvn	96,34%	65,85%	87,80%	64,63%
9	17.čvn	93,90%	69,51%	87,80%	79,27%
10	24.čvn	87,80%	58,54%	86,59%	65,85%
11	30.čvn	95,00%	61,25%	86,25%	71,25%
12	15.čvc	87,18%	53,85%	89,74%	69,23%

Tabulka 8: Přesnosti natrénování klasifikátorů (2 ekotypy)

hlavní komponenty. Hodnoty dvou hlavních komponent u středního sucha a kontroly jsou však jak kladné a záporné a neshlukují se dle skupiny.

Natrénování klasifikátorů proběhlo pro různé skupiny. V prvním případě byly rozděleny všechny semenáčky dle ekotypů (tabulka 8). Přesnost natrénování klasifikátorů dle dvou ekotypů byla nejvyšší u metody Linear Discriminant Analysis. V tomto případě bylo do správné třídy zařazeno přes 90 % semenáčků při deseti měřeních. Pouze 24.6. a 15.7. byla přesnost natrénování nižší než 90 %. Vysoké hodnoty přesnosti natrénování klasifikátorů byly také u metody Support Vector Machine. Zde se pohybovala přesnost mezi 80–90 % po všechna měření. Z časového hlediska nejsou v datech výrazné výkyvy v přesnostech natrénování. Lehký pokles v přesnostech klasifikátorů Linear Discriminant Analysis a Naive Bayes lze nalézt 24.6. a 15.7.

Měření	Datum	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	Fine k-th Nearest Neighbour
1	22.dub	45,12%	34,15%	50,00%	29,27%
2	29.dub	40,24%	26,83%	41,46%	21,95%
3	06.kvě	36,59%	31,71%	40,24%	29,27%
4	13.kvě	43,90%	37,80%	41,46%	37,80%
5	20.kvě	39,02%	31,71%	42,68%	35,37%
6	27.kvě	52,44%	31,71%	36,59%	39,02%
7	03.čvn	46,34%	32,93%	39,02%	34,15%
8	10.čvn	57,32%	32,93%	52,44%	29,27%
9	17.čvn	47,56%	40,24%	43,90%	28,05%
10	24.čvn	52,44%	37,80%	46,34%	28,05%
11	30.čvn	46,25%	35,00%	48,75%	31,25%
12	15.čvc	46,15%	41,03%	44,87%	43,59%

Tabulka 9: Přesnosti natrénování klasifikátorů (3 ošetření, nezávisle na ekotypu)

Dále byly klasifikátory natrénovány pro 3 míry záhlavky nezávisle na ekotypu (tabulka 9). Nejvyšší přesnosti natrénování lze nalézt u metod Linear Discriminant Analysis a Support Vector Machine. U těchto metod se pohybuje přesnost mezi 30 a 60 %. Z časového hlediska jsou nejvyšší přesnosti

Měření	Datum	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	Fine k-th Nearest Neighbour
1	22.dub	65,85%	58,54%	68,29%	56,10%
2	29.dub	39,02%	63,41%	70,73%	58,54%
3	06.kvě	53,66%	48,78%	58,54%	41,46%
4	13.kvě	70,73%	60,98%	65,85%	60,98%
5	20.kvě	65,85%	63,41%	48,78%	56,10%
6	27.kvě	60,98%	70,73%	65,85%	68,29%
7	03.čvn	75,61%	68,29%	65,85%	68,29%
8	10.čvn	80,49%	63,41%	60,98%	73,17%
9	17.čvn	68,29%	48,78%	68,29%	65,85%
10	24.čvn	75,61%	60,98%	70,73%	56,10%
11	30.čvn	82,05%	74,36%	66,67%	66,67%
12	15.čvc	82,05%	61,54%	71,79%	66,67%

Tabulka 10: Přesnosti natrénování klasifikátorů (náhorní ekotyp, 2 skupiny ošetření - silné sucho, zbytek)

natrénování 10.6. u metody Linear Discriminant Analysis (57 %) a Support Vector Machine (52 %). U metod Naive Bayes a Fine k-th Nearest Neighbour jsou nejvyšší přesnosti 15.7. (41 a 44 %).

Kvůli poměrně nízkým přesnostem při natrénování dle tří ošetření nezávisle na ekotypu byly dále klasifikátory natrénovány pro každý ekotyp zvlášť a pouze pro dvě skupiny ošetření – silné sucho a ostatní. Přesnosti natrénování klasifikátorů jsou pro jeden ekotyp a 2 skupiny ošetření vyšší než pro 3 skupiny ošetření u všech ekotypů. U náhorního ekotypu (tabulka 10) jsou nejvyšší přesnosti natrénování u Linear Discriminant Analysis 30.6. a 15.7. (82 %), tedy u dvou měření už po začátku regenerace. U metody Naive Bayes bylo nejvyšší procento semenáčků přiřazeno do správné skupiny 30.6. (74 %). Metoda Support Vector Machine byla nejpřesnější 15.7. (72 %) a metoda Fine k-th Neares Neighbour 10.6. (73 %).


Měření	Datum	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	Fine k-th Nearest Neighbour
1	22.dub	68,29%	46,34%	53,66%	60,98%
2	29.dub	70,73%	58,54%	65,85%	56,10%
3	06.kvě	68,29%	48,78%	53,66%	58,54%
4	13.kvě	73,17%	53,66%	56,10%	63,41%
5	20.kvě	70,73%	56,10%	53,66%	70,73%
6	27.kvě	75,61%	63,41%	56,10%	68,29%
7	03.čvn	68,29%	60,98%	58,54%	53,66%
8	10.čvn	75,61%	63,41%	63,41%	56,10%
9	17.čvn	80,49%	70,73%	75,61%	48,78%
10	24.čvn	80,49%	75,61%	70,73%	60,98%
11	30.čvn	73,17%	68,29%	63,41%	75,61%
12	15.čvc	69,23%	66,67%	69,23%	76,92%

Tabulka 11: Přesnosti natrénování klasifikátorů (pahorkatinný ekotyp, 2 skupiny ošetření - silné sucho, zbytek)


U pahorkatinného ekotypu (tabulka 11) byly nejvyšší přesnosti natrénování klasifikátorů rámcově dříve než u náhorního ekotypu. Metodou Linear Discriminant Analysis bylo nejvíce semenáčků správně zařazeno 17.6. a 24.6. (80 %) před začátkem regenerace. Nejvyšší přesnost metody Naive Bayes byla 10.6. (76 %) a metody Support Vector Machine 17.6. (76 %). Pouze metoda Fine k-th Nearest Neighbour měla nejvyšší přesnost natrénování v období regenerace a to 15.7. (77 %).

4.2.5 Vegetační indexy

Pro rychlou analýzu vývoje stavu borovic byl sledován vývoj hodnot celkem 5 vegetačních indexů. Hodnota každého indexu byla počítána jako průměr pro každý ekotyp a typ ošetření zvlášť (celkem 6 skupin).




Obrázek 27: Vývoj NDVI - náhorní ekotyp




Obrázek 28: Vývoj NDVI - pahorkatinný ekotyp

Hodnota indexu NDVI u náhorního ekotypu (obrázek 27) od počátku experimentu klesala u všech skupin ošetření až do 6.5. Poté hodnoty indexu stoupaly u skupiny kontrola a střední sucho až do konce měření. U skupiny silného sucha lze pozorovat pokles v hodnotách od 10. 6. do 24.6. Po začátku regenerace se hodnoty NDVI zvýšily v průměru o 0,04. U pahorkatinného ekotypu (obrázek 28) jsou hodnoty indexu NDVI u všech ošetření vyšší než u náhorního ekotypu. Do 6.5. lze také zaznamenat




Obrázek 29: Vývoj TCARI/OSAVI - náhorní ekotyp




Obrázek 30: Vývoj TCARI/OSAVI - pahorkatinný ekotyp

pokles hodnot, není však tak výrazný jako u náhorního ekotypu. Poté zůstávají hodnoty NDVI konstantní. Pouze u skupiny silného sucha lze zaznamenat pokles o 0,02 mezi 24. a 30.6.

Hodnoty indexu TCARI/OSAVI se u obou ekotypů v průběhu experimentu snížily o cca. 0,06 u kontroly a středního sucha. Výjimkou jsou semenáčky ze skupiny silného sucha. U náhorního ekotypu (obrázek 29) hodnoty indexu začínaly narůstat od 3.6. a do 24.6 se zvýšily o 0,02. Po začátku regenerace následoval pokles na hodnotu 0,17. U pahorkatinného ekotypu (obrázek 30) se u skupiny silného sucha začaly zvyšovat hodnoty až 10.6. Na rozdíl od náhorního ekotypu však trend pokračuje i po začátku regenerace a hodnoty indexu se od 10.6. do 15.7. zvýšily z 0,17 na 0,2.




Obrázek 31: Vývoj MSI - náhorní ekotyp




Obrázek 32: Vývoj MSI - pahorkatinný ekotyp

Hodnoty indexu MSI u náhorního ekotypu (obrázek 31) v průběhu experimentu klesaly u skupin kontrola a střední sucha. Naopak u skupiny silného sucha se zvýšila hodnota indexu od počátku experimentu až do začátku regenerace (24.6.) o 0,14. Po začátku regenerace hodnota indexu klesla u skupiny silné sucha o 0,06. U pahorkatinného ekotypu (obrázek 32) zůstávaly hodnoty MSI u kontroly a




Obrázek 33: Vývoj NDWI - náhorní ekotyp




Obrázek 34: Vývoj NDWI - pahorkatinný ekotyp

středního sucha mezi 0,54 a 0,57 od počátku měření do 30.6. U skupiny silného sucha lze pozorovat od 3.6. nárůst hodnot indexu až do 30.6. o 0,07. Mezi 30.6. a 15.7. klesla u všech skupin ošetření hodnota indexu o cca. 0,03-0,05.

Hodnoty indexu NDWI u náhorního ekotypu (obrázek 33) v průběhu měření mírně stoupaly u ošetření kontrola a střední sucho. Hodnoty se u těchto skupin pohybovaly v rozmezí -0,01 a 0,02. Pouze mezi 30.6. a 15.7. lze pozorovat silný nárůst o 0,03 a 0,04. U skupiny silného sucha hodnoty klesaly od počátku měření až do začátku regenerace, celkově o 0,07. Po 24.6. následoval do 15.7. nárůst z -0,01 na 0,05. U pahorkatinného ekotypu (obrázek 34) se hodnoty NDWI u skupiny kontrola a střední sucho pohybovaly až do 30.6. mezi -0,01 a 0,025. Mezi 30.6. a 15.7. následoval nárůst o 0,04. U skupiny silného sucha lze pozorovat pokles z 0,03 na -0,015 od počátku experimentu až do 30.6. Poté se hodnoty indexu do 15.7. také zvýšily o cca. 0,04 jako u ostatních dvou skupin ošetření.



Obrázek 35: Vývoj WBI – náhorní ekotyp




Obrázek 36: Vývoj WBI – pahorkatinný ekotyp

Hodnoty indexu WBI u náhorního ekotypu (obrázek 35) mírně klesaly po celou dobu experimentu u kontrolní skupiny a skupiny středního sucha. Přes celou dobu měření klesly o cca. 0,015. Průměrná hodnota indexu u silně stresovaných jedinců naopak až do regenerace stoupala. Především mezi 3.6. a 17.6. lze pozorovat výrazný nárůst hodnoty o 0,01. Od začátku regenerace do 30.6. klesla hodnota indexu na 0,97. U pahorkatinného ekotypu (obrázek 36) se pohybovaly hodnoty WBI u kontroly a středního sucha v rozmezí 0,965 do 0,975 po celou dobu experimentu. U skupiny silného sucha lze zaznamenat nárůst vegetačního indexu od 3.6. do 17.6. o 0,01. Po 17.6. se hodnota indexu držela až do konce experimentu mezi 0,985 a 0,99.


4.3 Vztah mezi laboratorními spektry a dalšími indikátory stresu

4.3.1 Vývoj obsahu chlorofylu

Obsah chlorofylu v semenáčcích borovice byl měřen od počátku experimentu do 30.6. Pro každý ekotyp a skupinu ošetření byla vypočítána pro každý den měření průměrná hodnota obsahu chlorofylu.




Obrázek 37: Vývoj obsahu chlorofylu - náhorní ekotyp




Obrázek 38: Vývoj obsahu chlorofylu - pahorkatinný ekotyp

U všech tří ošetření stoupal obsah chlorofylu u náhorního ekotypu (obrázek 37) z počátečních 70–80 $\mu\text{g}/\text{cm}^2$ naměřených 22.4. na 90–95 $\mu\text{g}/\text{cm}^2$ určených 3.6. Od 3.6. do 24.6. byl u všech tří ošetření zjištěn úbytek obsahu chlorofylu o 10–30 $\mu\text{g}/\text{cm}^2$, přičemž nejsilnější úbytek obsahu chlorofylu byl pozorován u jedinců se silným stresem z nedostatku vody. Po začátku regenerace se obsah chlorofylu zvýšil, do 30.6. narostl obsah chlorofylu o 5–15 $\mu\text{g}/\text{cm}^2$. U pahorkatinného ekotypu (obrázek 38) byl průběh obsahu chlorofylu podobný tomu u náhorního ekotypu. Do 3.6. narostl obsah chlorofylu u všech



Obrázek 39: Rozdíl obsahu chlorofylu od kontroly - náhorní ekotyp




Obrázek 40: Rozdíl obsahu chlorofylu od kontroly - pahorkatinný ekotyp

ošetření z 70–75 $\mu\text{g}/\text{cm}^2$ na 85–90 $\mu\text{g}/\text{cm}^2$. V období mezi 3.6. a 24.6. následoval úbytek obsahu chlorofylu o 10–20 $\mu\text{g}/\text{cm}^2$, nejsilnější úbytek (20 $\mu\text{g}/\text{cm}^2$) byl u silně stresovaných rostlin. Od začátku regenerace do 30.6. byl pozorován nárůst obsahu chlorofylu u všech skupin o cca. 5 $\mu\text{g}/\text{cm}^2$.

Na obrázku 39 je zobrazen rozdíl obsahu chlorofylu od kontrolní skupiny pro náhorní ekotyp. Hodnoty obsahu chlorofylu jsou u skupiny střední sucho vyšší než u skupiny kontrola u všech měření kromě 22.4. a 17.6. U skupiny silného sucha je obsah chlorofylu vyšší než u kontroly až do 10.6. Po tomto datu je obsah chlorofylu u skupiny silné sucho nižší. Nejvyšší rozdíl je 24.6., kdy je obsah chlorofylu o 13 $\mu\text{g}/\text{cm}^2$ nižší než u kontrolní skupiny. Oproti skupině středního sucha je v tento den obsah chlorofylu nižší o 18 $\mu\text{g}/\text{cm}^2$. U pahorkatinného ekotypu (obrázek 40) je obsah chlorofylu u skupiny středního sucha vyšší než u kontrolní skupiny po celou dobu měření kromě 3.6. a 17.6. Hodnoty obsahu chlorofylu jsou u skupiny silné sucho vyšší než u kontrolní skupiny až do 10.6. (s výjimkou 13.5.). Největší rozdíl mezi skupinou silné sucho a ostatními je 30.6. V tento den měření je obsah chlorofylu u silně stresovaných jedinců o 8 $\mu\text{g}/\text{cm}^2$ nižší než u kontrolní skupiny a o 10 $\mu\text{g}/\text{cm}^2$ nižší než u středně stresovaných jedinců.

4.3.2 Vývoj obsahu vody v půdě


Procentuální obsah vody v půdě byl sledován od 15.4. do 11.7. pomocí půdních sond. Sledován byl nezávisle na ekotypu, počítána byla vždy průměrná hodnota obsahu vody v půdě za daný typ ošetření.



Obrázek 41: Vývoj obsahu vody v půdě (nezávisle na ekotypu)

Průměrná hodnota procentuálního obsahu vody v půdě pro každou skupinu ošetření je zobrazena na obrázku 41. Ve vývoji obsahu vody v půdě lze vysledovat cykly po zalití semenáčků. Po

zálivce vždy prudce stoupl obsah vody v půdě u všech ošetření a následně do dalšího data zálivky klesal. Obsah vody v půdě u kontrolní skupiny se pohyboval mezi 20 a 60 %. Až do začátku regenerace byl obsah vody v kontrolní skupině vždy vyšší než u ostatních dvou skupin. Nejvyšší procentuální obsah vody u této skupiny byl 5.5. se 61 %. Po tomto datu obsah vody u této skupiny klesal. U skupiny silné sucho se pohybuje procentuální obsah vody mezi 0 a 50 %. Na počátku experimentu, kdy ještě byla skupina silného sucha také zalévána, lze pozorovat nárůst obsahu vody s maximem 1.5. (50 %). Poté následoval pokles obsahu vody. Od 21.5. nebyla skupina silného sucha zalévána vůbec a hodnoty obsahu vody klesaly k minimu 10.6. (5 %). Od počátku regenerace 24.6. silně narostly hodnoty obsahu vody s maximem 50 %. Hodnoty obsahu vody u skupiny středního sucha se pohybovaly mezi kontrolní skupinou a skupinou silného sucha. Po celou dobu experimentu se obsah vody pohyboval mezi 0 a 55 %. Nejvyšší hodnoty obsahu vody u této skupiny byly v období regenerace (55 %). Nejnižší hodnoty byly naopak zaznamenány 17.6. (0 %) a 24.6. (5 %).




Obrázek 42: Rozdíl obsahu vody od kontrolní skupiny (nezávisle na ekotypu)

Na rozdílu obsahu vody mezi kontrolou a ostatními ošetřeními (obrázek 42) lze pozorovat, že kontrolní skupina měla až do 24.6. vyšší obsah vody než ostatní dvě ošetření. Po začátku regenerace se to změnilo a od 29.6. měla nejvyšší obsah vody v půdě skupina silně stresovaná nedostatkem vody, následována skupinou středního sucha. Skupina silně stresovaných jedinců měla nižší obsah vody než skupina středního sucha od 20.4. do 30.4 a od 4.5. do 28.6. Od kontroly se skupina nejvíce lišila 9.6., kdy

byl procentuální obsah vody o 44 % nižší. Také 18.6. a 3.6. dosahoval rozdíl obsahu vody mezi kontrolou a silně stresovanými jedinci až 33 %. U skupiny středního sucha nebyly tak výrazné rozdíly obsahu vody s kontrolní skupinou. V průběhu experimentu se pohyboval obsah vody o 15 % níže než u kontrolní skupiny. Největší rozdíl byl mezi 15. a 20.4., kdy byl obsah vody v půdě u středně stresovaných jedinců až o 30 % nižší než u kontrolní skupiny.


4.3.3 Regrese mezi spektrálními daty a obsahem chlorofylu z CCM

Lineární regrese pro určení závislosti mezi spektrálními daty a obsahem chlorofylu byla vypočítána jednak pro každé spektrální pásmo a také pro všechny poměrové indexy, které šly ze spektrálních dat vytvořit. Obsah chlorofylu v rostlině byl získán z měření CCM. Regrese byla provedena ze všech měření mezi 22.4. a 30.6.



Obrázek 43: Míra korelace mezi obsahem chlorofylu (z CCM) a odrazivostí v každé vlnové délce

Hodnoty koeficientu determinace pro lineární regresi mezi obsahem chlorofylu a odrazivostí jsou velice nízké ve všech spektrálních pásmech (obrázek 43). Hodnoty R^2 se pohybují mezi 0 a 0,28. Nejvyšší hodnoty R^2 jsou v pásmech zeleného záření s minimem v 548 nm ($R^2 = 0,28$). Zvýšení hodnoty koeficientu lze pozorovat také v oblasti *red edge* kolem 710 nm ($R^2 = 0,22$). Plot mezi hodnotami odrazivosti v 548 nm a obsahem chlorofylu je na obrázku 44. Z hodnot obsahu chlorofylu a odrazivosti je zřejmá vysoká variabilita v datech, která způsobuje nízkou hodnotu koeficientu determinace.



Obrázek 44: Plot mezi obsahem chlorofylu (z CCM) a odrazivostí v 548 nm

Poměry pásem, které měly nejvyšší hodnotu koeficientu determinace se pohybují mezi 630–690 nm (tabulka 12). Nejvyšší míru korelace s obsahem chlorofylu měl poměrový index mezi 680 a 690 nm, a to 0,4099. Vyšší hodnotu korelačního koeficientu, než jakýkoliv poměr pásem měl vegetační index TCARI/OSAVI (tabulka 13), a to 0,47. Vegetační index NDVI měl naopak hodnotu koeficientu determinace pouze 0,11.

Pásmo 1 (nm)	Pásmo 2 (nm)	R ²
630	660	0,3960
650	640	0,3985
670	660	0,3987
660	640	0,4012
680	630	0,4039
680	640	0,4039
670	630	0,4039
670	650	0,4052
670	640	0,4083
680	690	0,4099


Tabulka 12: Poměry pásem s nejvyšší hodnotou koeficientu determinace (obsah chlorofylu z CCM x spektra)

Index	R ²
TCARI/OSAVI	0,4699
NDVI	0,1108

Tabulka 13: Korelace obsahu chlorofylu z CCM s vybranými vegetačními indexy

4.3.4 Regrese mezi spektrálními daty a laboratorně stanoveným obsahem chlorofylu


Obsah chlorofylu v jehlicích byl určen laboratorní analýzou v průběhu celého experimentu dvakrát – 22.4. a 30.6. Lineární regrese mezi laboratorně určeným obsahem chlorofylu a spektrálními daty byla vypočítána z datové sady z těchto dvou dnů. Koeficient determinace byl určen pro každou vlnovou délku, všechny jednoduché poměrové indexy a vegetační indexy NDVI a TCARI/OSAVI.



Obrázek 45: Míra korelace mezi obsahem chlorofylu (laboratorně stanoveným) a odrazivostí v každé vlnové délce

Hodnoty koeficientu determinace pro lineární regresi mezi laboratorně stanoveným obsahem chlorofylu a spektrálními daty (obrázek 45) jsou celkově vyšší než u regrese mezi spektry a obsahem chlorofylu měřeným pomocí přístroje CCM. Pohybují se mezi hodnotami 0 a 0,46. Nejvyšší hodnoty R^2 lze nalézt v oblasti zeleného záření s maximem v 543 nm s hodnotou $R^2 = 0,46$. Vyšší hodnoty koeficientu determinace lze také nalézt v oblasti červeného záření na 680 nm ($R^2 = 0,33$) nebo druhém absorpčním minimu vody na 1928 nm ($R^2 = 0,28$).

Na obrázku 46 je zobrazen plot mezi hodnotami odrazivosti v 543 nm, kde byla vypočítána nejvyšší hodnota koeficientu determinace, a laboratorně stanoveným obsahem chlorofylu. Ze vztahu mezi veličinami lze vysledovat negativní korelaci – čím vyšší odrazivost v tomto pásmu, tím nižší obsah chlorofylu. Několik naměřených vzorků však tomuto vztahu neodpovídá, což způsobuje vyšší variabilitu v datech a poměrně nízkou hodnotu R^2 .



Obrázek 46: Plot mezi hodnotami odrazivosti v 543 nm a laboratorně stanoveným obsahem chlorofylu


Poměry pásem, které měly nejvyšší hodnotu koeficientu determinace, byly počítány z vlnových délek mezi 590 – 690 nm (tabulka 14). Nejvyšší hodnotu R^2 měl poměrový index 680/610 nm, a to 0,68. Vegetační indexy NDVI a TCARI/OSAVI měly hodnoty koeficientu determinace nižší než poměrové indexy z oblasti 590 – 690 nm (tabulka 15). Více než NDVI koreloval s obsahem chlorofylu index TCARI/OSAVI s hodnotou $R^2 = 0,56$.

Pásmo 1 (nm)	Pásmo 2 (nm)	R^2
590	690	0,6689
600	680	0,6744
600	690	0,6748
630	690	0,6748
680	630	0,6755
610	690	0,6775
680	640	0,6776
620	690	0,6783
680	620	0,6795
680	610	0,6806


Tabulka 14: Poměry pásem s nejvyšší hodnotou koeficientu determinace (obsah laboratorně stanoveného chlorofylu x spektra)

Index	R^2
TCARI/OSAVI	0,5643
NDVI	0,4241

Tabulka 15: Korelace laboratorně stanoveného chlorofylu s vybranými vegetačními indexy



Obrázek 47: Vývoj indexu 680/610 nm - náhorní ekotyp




Obrázek 48: Vývoj indexu 680/610 nm - pahorkatinný ekotyp

Hodnoty poměrového indexu 680/610, který měl nejvyšší korelaci s laboratorně stanoveným obsahem chlorofylu, byly po celou dobu měření vyšší u náhorního ekotypu (obrázek 47). U všech tří ošetření lze pozorovat nárůst hodnoty indexu až do 13.5., poté zůstávaly hodnoty mezi 0,95 a 1,15. Od 13.5. měla nejnižší hodnoty indexu skupina silné sucho. U této skupiny lze také pozorovat mírný pokles o 0,02 mezi 3.6. a 10.6., od 17.6. však hodnoty indexu u této skupiny opět narůstaly až na 1,1 (15.7.). U pahorkatinného ekotypu (obrázek 48) lze také pozorovat nárůst hodnot od počátku měření do 13.5. u všech tří skupin. Nejvyšší hodnoty indexu má skupina silné sucho od 22.4. až do 3.6., poté hodnoty indexu u této skupiny klesaly. Nejnižší hodnoty má skupina silné sucho 24.6., a to 0,87. U skupin kontrola a střední sucho lze pozorovat mírný nárůst hodnot indexu až do 1.7., kdy maximum skupiny kontrola činilo 0,95 a skupiny střední sucho 0,9.

4.3.5 Regrese mezi spektrálními daty a obsahem vody v jehlicích


Lineární regrese pro určení závislosti mezi obsahem vody v jehlicích a spektrálními daty byla počítána pro každou měřenou vlnovou délku a všechny jednoduché poměrové indexy. Obsah vody v jehlicích byl měřen za celý experiment dvakrát – na počátku 22.4. a ke konci 30.6. Regrese proto byla provedena pouze na skupině dat složených z těchto dvou dnů.



Obrázek 49: Míra korelace mezi obsahem vody a odrazivostí v každé vlnové délce

Hodnoty koeficientu determinace jsou velice rozdílné přes celé měřené spektrum a pohybují se mezi 0 – 0,67 (obrázek 49). Nejvyšší hodnoty R^2 lze nalézt v prvním absorpčním pásmu vody s maximem v 1400 nm ($R^2 = 0,66$) a na počátku druhého absorpčního pásma vody s maximem v 1885 nm ($R^2 = 0,67$). Vysoké hodnoty R^2 jsou také v oblasti viditelného záření v rozmezí 500–700 nm. Hodnoty R^2 se v této oblasti pohybují mezi 0,4 a 0,6. Nejnížší hodnoty koeficientu determinace jsou v pásmech blízkého infračerveného záření mezi 750–1300 nm a na počátku spektrální křivky.

Z plotu mezi hodnotami obsahu vody v jehlicích a odrazivostí v 1885 nm (kde byla nejvyšší hodnota koeficientu determinace) na obrázku 50 lze vysledovat negativní korelaci mezi veličinami. Čím vyšší jsou hodnoty odrazivosti v 1885 nm, tím nižší je procentuální obsah vody v jehlicích.



Obrázek 50: Plot mezi obsahem vody a odrazivostí v 1885 nm


Z poměrů pásem měly nejvyšší hodnotu koeficientu determinace indexy počítané z odrazivosti v 1880 nm a v 1430-1450 nm (tabulka 16). Nejvyšší hodnotu R^2 měla lineární regrese mezi obsahem vody a poměrem pásem 1880/2130, a to 0,81. Z vegetačních indexů (tabulka 17) nejvíce koreloval s obsahem vody index WBI ($R^2 = 0,67$) následovaný indexem MSI ($R^2 = 0,5$). Všechny vegetační indexy však měly nižší hodnoty koeficientu determinace než poměry pásem zmíněné v tabulce 16.

Pásmo 1 (nm)	Pásmo 2 (nm)	R^2
1430	2250	0,7959
1440	2270	0,7968
1450	2270	0,7982
1880	2110	0,7994
1880	2170	0,8045
1880	2140	0,8107
1880	2150	0,8134
1880	2160	0,8138
1880	2120	0,8150
1880	2130	0,8188


Tabulka 16: Poměry pásem s nejvyšší hodnotou koeficientu determinace (obsah vody x spektra)

Index	R^2
NDVI	0,2828
MSI	0,5007
WBI	0,6651
NDWI	0,3385

Tabulka 17: Korelace obsahu vody s vybranými vegetačními indexy



Obrázek 51: Vývoj indexu 1880/2130 nm – náhorní ekotyp



Obrázek 52: Vývoj indexu 1880/2130 nm - pahorkatinný ekotyp

Vývoj poměrového indexu z vlnových délek 1880 a 2130 nm má podobnost s indexem WBI. U náhorního ekotypu (obrázek 51) lze pozorovat pokles hodnot indexu u skupin kontrola a střední sucho od 6.5. do 24.6. z hodnot 1,15 na 1,04-1,05. Naopak u skupiny silného sucha lze pozorovat od 27.5. nárůst hodnot indexu z 1,08 až na 1,14 naměřených 24.6. U pahorkatinného ekotypu (obrázek 52) se pohybují hodnoty indexu u kontroly a středního sucha mezi 1 a 1,07 po celou dobu experimentu. Skupina silného sucha má vždy vyšší hodnoty indexu ostatní skupiny ošetření. Od 3.6. lze pozorovat nárůst hodnot indexu u silně stresovaných jedinců z 1,08 na 1,11. Nejvyšší hodnota indexu je u skupiny silné sucho 15.7. (1,18).

5 Diskuse

Prvním cílem této práce bylo navrhnout nedestruktivní způsob měření semenáčků jehličnanů spektrometrem. Zhodnocení, do jaké míry byl způsob měření přesný, je obtížné, vzhledem k výsledkům této práce se však způsob měření semenáčků borovic projevil jako vhodný. Při sestavování měřicí aparatury byl kladen důraz na dva aspekty. Jednak bylo třeba eliminovat šum v datech, tedy minimalizovat faktory, které by mohly ovlivnit měření spekter. Druhým cílem bylo navrhnout soustavu tak, aby bylo možné měřit semenáčky pokaždé v naprosto stejných podmínkách.

Toho, aby měření nebylo ovlivněno jinými faktory, bylo docíleno kompletním zatemnění místnosti. Také skříň, ve které byly umístěny semenáčky borovice, byla natřena černou barvou, jejíž odrazivost se v každé vlnové délce blížila nule. Přesnost měření byla udržována častým měřením bílé reference. Například zvýšení obsahu vody ve vzduchu způsobené přítomností osob v místnosti způsobovalo lehké snížení odrazivosti v absorpčních minimech vody, proto bylo nutné měřit bílou referenci alespoň každých 10 minut.

Stejné podmínky pro měření borovic při každém měření byly zajištěny fixací jednotlivých komponent na pracovišti. Grip pistole, světla a černá skříň byly po celou dobu měření v jedné pozici připevněné lepicími páskami. Hever se stojanem na semenáčky a stativ s bílou referencí musely být ze skříně odstranitelné. To, aby jejich pozice byla vždy stejná, bylo zajištěno značkami na dnu černé skříně. Dále bylo nutné snímat vždy stejnou část borovice při každém měření. Toho bylo docíleno zaznamenáním výšky heveru pro každý semenáček a strany, ze které je semenáček měřen.

Dalším krokem, který silně ovlivnil naměřené radiometrické hodnoty, byl přepočet odrazivosti s pomocí fotografie semenáčku popsany v kapitole 3.2.3. Pro tento krok bylo nutné dodržet přesné vzdálenosti při kalibraci fotoaparátu i při měření semenáčků – například vzdálenost fotografovaného štítu a vzdálenost rostlin od optického kabelu. Vzhledem ke změnám v hodnotách variačního koeficientu (na obrázku 14) přepočet radiometrických hodnot splnil svůj účel. V oblastech, kde byla vysoká variabilita v datech způsobena rozdílností mezi semenáčky (dle hodnot *eigenvectors* z PCA na obrázku 23 se jedná o oblasti červeného spektra s minimem v 700 nm nebo oblast druhého absorpčního pásma vody s minimem v 1900 nm), zůstala vysoká hodnota variačního koeficientu i po úpravě spekter. Naopak v oblastech, kde byla vysoká variabilita způsobena procentuálním zastoupením semenáčku v zorném poli optického kabelu (např. oblast NIR mezi 750-1300 nm), byl variační koeficient hodnot odrazivosti po úpravě snížen.

I přes poměrně přesné měření, ve kterém bylo možné detekovat jak ekotypy, tak změny mezi mírou zálivky, je nutné upozornit na některá úskalí tohoto způsobu měření. Jedním problémem byla změna ve vzhledu borovic, která ovlivnila oblast semenáčku, na které byla měřena odrazivost. Semenáčkům ze skupiny silné sucho ke konci měření poklesly jehlice a také se naklonily semenáčky

samotné. To způsobilo, že nebylo u některých jedinců možné snímat stejnou oblast po celou dobu měření. Další skutečnost, která mohla ovlivnit přesnost měření, je zorné pole optického kabelu. Čím větší je vzdálenost od optického kabelu, tím větší plocha je měřena. Při tomto experimentu byl kalibrován přepočít radiometrických hodnot pro vzdálenost objektu 24 cm od optického kabelu, jelikož se předpokládalo, že rostliny, bílá reference i fotografovaný štít budou v této vzdálenosti. Některé rostliny svým náklonem způsobily, že jejich vzdálenost byla od optického kabelu o několik centimetrů vyšší nebo nižší. Pokud byl například semenáček nakloněn blíže k optickému kabelu, vstupovala do zorného pole optického kabelu menší plocha. Na fotografii však bylo předpokládáno, že stále vstupuje do měření kruh s poloměrem 5,3 cm. Tento nepoměr mohl způsobit, že pro několik jedinců byl spočítaný poměr mezi měřenou rostlinou a černým pozadím o několik procent špatně. Při měření také nebyla brána v potaz geometrie jehlic, vrhaný stín semenáčkem a bylo počítáno s pouze čistě lineárním vztahem – tedy s tím, že naměřený signál je vážený součet odrazivosti z černé krabice a semenáčku borovice.

Obdobný způsob měření spekter, jako byl použit v tomto experimentu, nebyl autorem této práce nalezen v žádné z analyzovaných publikací. Proto lze tento způsob porovnat pouze s jinými metodami měření spekter. Oproti některým metodám v literatuře má tento způsob výhodu, že je nedestruktivní a není nutné odebírat jehlice. Měření odebraných jehlic prováděli například Moran et al. (2000) nebo Zhang et al. (2008). V tomto případě je však nutné odebrat velké množství jehlic (Moran et al. 2000) nebo snímat malé množství, které nemusí obsáhnout celou variabilitu jedince (Zhang et al. 2008). Ani vytvoření husté mřížky z jehlic nemusí někdy stačit, aby nebylo v signálu obsaženo pozadí. Na tento problém narazili Stimson et al. (2005) při měření jalovce (pokrytí mřížky bylo pouze 62 %). Nízkou korelaci mezi spektrálními daty a obsahem vody v jehlicích přisuzují autoři právě nízkému pokrytí mřížky při měření spektrometrem. Nedestruktivní měření jehličnanů prováděli například van Aardt a Wynne (2001). V jejich případě byla měřena spektra jednotek jehlic, aby nevstupovalo do měření pozadí jehlic. To však vedlo k tomu, že bylo nutné velice velké množství měření pro jednu skupinu (10 x 50 měření), aby byla pokryta variabilita mezi jedinci. Podobnost s navrženou měřicí soustavou lze nalézt u Cháveze et al. (2013). V tomto experimentu byly měřeny spektrometrem semenáčky *Naditce tamarugo* (*Prosopis tamarugo*) z nadiru a z takové blízkosti, aby do měření nevstupovalo pozadí. Tento způsob měření v našem případě nebyl možný, protože borovicím začaly na vrcholech růst nové výhonky. Při měření z nadiru by nebyla snímána stejná část rostliny po celou dobu měření. Z těchto důvodů se i přes zmíněné nevýhody stále jeví navržená měřicí soustava jako nejlepší možnost pro snímání dvouletých semenáčků borovic.

Druhým cílem této práce bylo zjistit, zda se v laboratorních spektrech semenáčků borovice projeví vodní stres různé intenzity a zda se bude reakce borovic lišit dle ekotypu. První analýzou, která byla za tímto účelem využita, byl smíšený statistický model. Cílem bylo zjistit, zda se skupiny odlišovaly

po celou dobu měření (obrázek 16). Tento statistický model podle očekávání vyhodnotil, že se skupiny dle zálivky po celou dobu měření statisticky významně v žádném spektrálním pásmu nelišily. Tento krok byl důležitý pro zjištění, zda nebyl mezi skupinami nějaký další faktor, který mohl vést k tomu, že se by se skupiny lišily po celou dobu měření.

Dále byly pro každé datum měření zpracovány analýzy rozptylu, pomocí kterých byla určena pásma, ve kterých se statisticky významně liší skupiny dle zálivky. Počet pásem, ve kterých se skupiny statisticky významně lišily, jsou uvedeny v tabulce 7. Překvapivé je, že se v několika pásmech odlišovaly skupiny dle zálivky na počátku měření. U náhorního ekotypu to bylo 30 a 127 pásem u prvních dvou měření, u pahorkatinného kolem 300-350 pásem, která přetrvala až do 10.6. Tato skutečnost mohla být způsobena šumem v datech. Tuto domněnku by mohla podpořit skutečnost, že se signifikantně odlišná pásma nacházela na počátku spektrální křivky (viz obrázek 19).

Nárůst počtu signifikantně odlišných spektrálních pásem lze u obou ekotypů sledovat mezi 3.6. a 10.6., přičemž se nárůst týká vlnových délek v absorpčních pásmech vody, což jednoznačně odkazuje na vodní stres. Počátek, kdy lze pozorovat vliv stresu z nedostatku vody, se dle ekotypu neliší. Rozdíl v reakci mezi ekotypy však je po začátku regenerace. U náhorního ekotypu se po regeneraci opět snižuje počet signifikantně odlišných vlnových délek (30.6. byl počet 36 a 15.7. počet 1). Naopak u pahorkatinného ekotypu se nadále zvyšuje počet pásem, ve kterých jsou skupiny dle zálivky signifikantně odlišné s maximem tři týdny po začátku regenerace (15.7. s počtem 1428). Z těchto výsledků lze usoudit, že se borovice náhorního ekotypu podstatně rychleji a lépe regenerovaly než semenáčky pahorkatinného ekotypu.

Dalším zvoleným indikátorem toho, zda se skupiny dle ošetření liší, byly přesnosti natrénování klasifikátorů. V tomto experimentu však byly přesnosti spíše ovlivněné velikostí trénovací skupiny. Na tento fakt poukazuje rozdíl mezi tabulkou 9 a 10. Vyšší hodnoty přesnosti natrénování klasifikátorů byly nalezeny po snížení skupin dle ošetření ze 3 (silné sucho, střední sucho a kontrola) na 2 (silné sucho a zbytek) a uvážení pouze jednoho ekotypu, a to i v době, kdy se skupiny dle ošetření ještě nelišily. Přesnosti natrénování klasifikátorů je tedy třeba brát spíše jako orientační údaje. Nejvyšší přesnosti natrénování klasifikátorů lze u obou ekotypů nalézt mezi 10.6. a 15.7., což podporuje výsledky analýzy rozptylu.

Největší změnu v hodnotách vegetačních indexů zaměřených na obsah vody v rostlině (především MSI a WBI) lze pozorovat mezi 3.6. a 10.6. u skupiny silné suchu u obou ekotypů. Zajímavé je, že u pahorkatinného ekotypu tento trend lze pozorovat již od 27.5. Po začátku regenerace se hodnoty většiny vegetačních indexů skupiny silné suchu u náhorního ekotypu zcela vrátí k hodnotám skupin kontrola a střední sucho. U pahorkatinného ekotypu nejsou hodnoty vegetačních indexů skupiny silné suchu po začátku regenerace tak odlišné od ostatních jako 24.6. (10. měření), zůstávají však stále rozdílné od skupin kontrola a střední sucho. Tento fakt podporuje výsledky analýzy rozptylu, dle které u

pahorkatinného ekotypu po začátku regenerace dále narůstají pásma, ve kterých se signifikantně liší skupiny dle zálivky. Z hodnot vegetačních indexů lze dále vyzorovat, že se skupina střední sucho liší velice málo od skupiny kontrola. Byť se v absolutních hodnotách indexů skupiny střední sucho a kontrola odlišují, jejich průběh je po celou dobu experimentu velice podobný. Z vývoje vegetačních indexů lze vyvodit, že zálivka klasifikovaná jako střední sucho nestačila vyvolat takové změny ve spektrálním projevu semenáčků, aby bylo možné skupiny střední sucho a kontrola od sebe spektrálně odlišit.

Úbytek obsahu chlorofylu (naměřený přístrojem CCM-300) u skupiny silné sucho lze pozorovat u náhorního ekotypu od 3.6., u pahorkatinného ekotypu od 10.6. až do začátku regenerace. Měření přístrojem CCM-300 však nebylo přesné. Už při měření bylo možné vysledovat závislost mezi měřenými hodnotami a tím, jak moc jsou nabitě baterie. Na nepřesnost v měření obsahu chlorofylu poukazují také nízké hodnoty korelačního koeficientu při regresi mezi hodnotami obsahu chlorofylu z CCM a hodnotami odrazivosti (s maximem $R^2 = 0,28$). Vyšší hodnoty koeficientu determinace byly spočítány při regresi mezi laboratorně stanoveným obsahem chlorofylu a poměrovými indexy počítanými z oblasti mezi 600-700 nm. Konkrétně poměrový index 680/610 nm měl nejvyšší hodnotu korelace s obsahem chlorofylu ($R^2 = 0,68$). Pokud by byl vývoj tohoto indexu vázán na obsah chlorofylu, lze pozorovat mírný úbytek obsahu chlorofylu u skupiny silné sucho u náhorního ekotypu od 3.6., u pahorkatinného ekotypu už od 27.5. (obrázky 47, 48).

Data ze sond v půdě semenáčků potvrdila, že se podařilo držet po dobu experimentu požadovaný obsah vody v půdě (obrázek 42). Nejnížší obsah vody v půdě měla skupina silné sucho a nejvyšší skupina kontrola. S laboratorně zjištěným obsahem vody nejvíce korelovaly hodnoty odrazivosti v absorpčních pásmech vody a poměrový index 1880/2130 nm ($R^2 = 0,81$). Pokud by tento index indikoval obsah vody, lze pozorovat změnu u skupiny silné sucho od 27.5. u obou ekotypů. Na hodnotách indexu jsou vidět přetrvávající rozdíly v obsahu vody po začátku regenerace u pahorkatinného ekotypu, což podporuje výsledky analýzy rozptylu.

Při porovnání s literaturou lze potvrdit závěry Cháveze et al. (2013), kteří pozorovali nejvyšší korelaci mezi obsahem vody v jehlicích s indexem Water Index (900/970 nm). Z pozorovaných literaturou uznávaných vegetačních indexů v této práci koreloval nejvíce s obsahem vody v jehlicích Water Band Index (970/900 nm) s $R^2 = 0,66$, což je alternace indexu WI. Chávez et al. (2013) však nepočítali všechny poměrové indexy, jež lze spočítat, tudíž nelze porovnat poměry vlnových délek ve středním infračerveném spektru, které u tohoto experimentu korelovaly s obsahem vody v jehlicích ještě více. Naopak výsledky práce Stimsona et al. (2005), kteří pozorovali u borovice jedlé nejvyšší korelaci mezi obsahem vody s indexem NDVI ($R^2 = 0,72$) a NDWI ($R^2 = 0,68$), se liší od výsledků této práce. Při tomto experimentu měly tyto dva indexy nejnížší hodnoty koeficientu determinace – NDVI s $R^2 = 0,28$ a NDWI s $R^2 = 0,34$. Potvrdit lze tvrzení Buddenbauma et al. (2015), že pro robustní odhad obsahu vody je nutné brát v potaz odrazivost v oblasti středního infračerveného záření (1000-2500 nm).

V tomto laboratorním měření s obsahem vody korelovaly nejvíce pásma a poměrové indexy právě z této oblasti. Z dat získaných přístrojem CCM a z hodnot odrazivosti nebylo možné odvodit výrazný úbytek chlorofylu. Je možné, že došlo k nepřesnému měření přístrojem CCM a že regrese nedokázala odhalit citlivá spektrální pásma na obsah chlorofylu. Nelze proto porovnat výsledky této práce s články Conroye et al. (1986) a Manese et al. (2001), kteří pozorovali signifikantní úbytek obsahu chlorofylu po navození stresu z nedostatku vody.

Třetím cílem práce bylo zjistit, zda je možné v obrazových a laboratorních spektrech rozlišit rozdílné ekotypy borovice lesní. U obrazových dat byla odlišnost ekotypů hodnocena analýzou rozptylu, analýzou hlavních komponent a natrénováním čtyř klasifikátorů. Z analýzy rozptylu vyplynulo, že se ekotypy statisticky významně odlišují ve všech vlnových délkách, kromě několika oblastí kolem 420 a 720 nm. Pomocí analýzy rozptylu bylo také vyhodnoceno, že se významně liší tři semenné sady ve všech vlnových délkách. Otázka, zda se více různí náhorní ekotyp od pahorkatinného než tři semenné sady od sebe navzájem, byla zkoumána analýzou hlavních komponent (obrázek 13). Hodnoty prvních dvou hlavních komponent byly u náhorního ekotypu podstatně odlišnější než u pahorkatinného. Také přesnost natrénování klasifikátorů byla u všech čtyř klasifikátorů vyšší pro dva ekotypy než pro 3 semenné sady.

Významným indikátorem odlišnosti dvou ekotypů u laboratorních dat byl smíšený statistický model (obrázek 15). Dle tohoto modelu se ekotypy statisticky významně liší ve většině spektrálních pásem, a to i přes variabilitu v různých dnech měření. Toto poukazuje na to, že ekotypy jsou odlišitelné i přes změny v odrazivosti vlivem navozeného sucha.

Počet pásem, ve kterých se dle analýzy rozptylu statisticky významně lišily ekotypy při každém měření zvlášť, je uveden v tabulce 6. Vysoký počet pásem, ve kterých se ekotypy různí (nad 900), byl přes celou dobu experimentu vyjma prvních dvou a posledních dvou měření. Na počátku měření mohl být nižší počet pásem způsoben aklimací borovic na nové prostředí. Jednotlivé semenáčky se vzhledově mezi sebou do značné míry lišily, a na nové prostředí se přizpůsobovaly postupně, což mohlo mít znatelný vliv na variabilitu v hodnotách odrazivosti. Nižší počet pásem ke konci měření lze odůvodnit vysokou variabilitou ve spektrálních křivkách u pahorkatinného ekotypu, kde se silně lišily skupiny dle ošetření. Pozoruhodná je změna vlnových délek, ve kterých se ekotypy statisticky významně liší. Na počátku měření se ekotypy odlišovaly v absorpčních pásmech vody a chlorofylu (obrázek 17). Ke konci měření (obrázek 18), kdy už byl navozen stres z nedostatku vody a v rámci ekotypů se silně různily jedinci dle obsahu vody, byly ekotypy statisticky významně odlišné hlavně v infračervené oblasti mezi 750-1300 nm. Tato změna mohla být způsobena zvýšením variability v oblasti absorpčních pásem vody (navozenou různou mírou závlivy mezi jedinci) v rámci jednotlivých ekotypů, což mohlo vést ke snížení statisticky významně odlišných vlnových délek v těchto oblastech.

Z analýzy hlavních komponent nejsou tak zřetelné rozdíly mezi ekotypy, jako u obrazových dat (obrázky 23 a 24). Přesto se ekotypy shlukují především v hodnotách druhé hlavní komponenty. Přesnosti natrénování klasifikátorů jsou vysoké po celou dobu měření a v čase nejsou zjevné významné výkyvy. Oproti obrazovým datům jsou nižší přesnosti natrénování u metod Naive Bayes a Fine KNN (tabulka 11).

Při porovnání s článkem od Danuseviciuse et al. (2014), kteří rozlišovali různé provenience borovice lesní, byly v našem experimentu dosaženy vyšší přesnosti natrénování klasifikátorů. S pomocí diskriminační analýzy byli autoři článku schopni zařadit 56–89 % jedinců do správné provenience. V našem experimentu se u lineární diskriminační analýzy pohybovaly přesnosti křížové validace mezi 87–99 % pro natrénování dvou ekotypů. Danusevicius et al. (2014) pozorovali v 5měsíčním období velké rozdíly mezi přesnostmi natrénování, což odůvodňují posunutými fenologickými cykly mezi proveniencemi borovice lesní. To z výsledků této práce nelze vyvodit. Borovicím v průběhu experimentu začaly růst nové výhonky a v rámci jednotlivých ekotypů byla navozena velká variabilita mezi jedinci způsobená stresem z nedostatku vody. Přesto byly přesnosti natrénování lineární diskriminační analýzy pro dva ekotypy vždy vyšší než 87 % a nebylo možné pozorovat výrazné změny v přesnostech natrénování klasifikátorů v průběhu experimentu. Van Aardt a Wynne (2001 a 2005) pomocí obrazových i laboratorních hyperspektrálních dat odlišovali různé druhy borovice (*Pinus taeda*, *Pinus virginiana*, *Pinus echinata*). Druhy dokázali odlišit v prvním článku s přesností 83 %, v druhém článku s přesností 85 %. V našem experimentu byly pozorovány vyšší přesnosti zařazení jedinců dle ekotypu borovice lesní jak u obrazových, tak laboratorních dat. Van Aardt a Wynne (2001 a 2005) diskutují, že pro spektrální odlišení druhů borovic jsou vhodná pásma viditelného a blízkého infračerveného spektra (350–1700 nm) a že pásma středního infračerveného spektra (1700–2500 nm) nejsou potřebná. V naší práci byla u laboratorních dat pozorována změna pásem, ve kterých se ekotypy statisticky významně liší. Na počátku experimentu bylo velké množství vlnových délek, ve kterých se ekotypy signifikantně odlišovaly, právě v oblasti středního infračerveného spektra (obrázek 17). Až ke konci experimentu narostl počet signifikantně odlišných pásem v oblasti viditelného a blízkého infračerveného záření (obrázek 18). Z výsledků naší práce proto nelze apriorně stanovit, jaká pásma jsou pro rozlišení ekotypů potřebná a jaká ne.

Z hlediska cílů lze shrnout, že byla navržena soustava k měření spekter, která byla pro účel experimentu vhodná. Přestože u soustavy byly zdokumentovány některé nedostatky, pro zpracování spektrálních dat byla dostačující. Navržený způsob měření spekter navíc kompenzoval nedostatky jiných způsobů měření spektrálních dat pozorovaných v literatuře.

V laboratorních spektrech semenáčků byl pozorován stres z nedostatku vody a byl potvrzen několika analytickými metodami. Vodní stres však byl detekován pouze u skupiny silné sucho. Zálivka u

skupiny střední sucho (tabulka 4) nebyla natolik nízká, aby mohla být tato skupina odlišena od dostatečně zalévaných jedinců. Stres ze sucha byl pozorován u obou ekotypů od 10.6., počáteční reakce se dle ekotypu nelišila. Rozdílnost mezi ekotypy šla vysledovat ve fázi regenerace. Semenáčky náhorního ekotypu regenerovaly rychleji, po 3 týdnech od počátku regenerace nebylo mezi skupinami dle ošetření možné detekovat rozdíly. U pahorkatinného ekotypu od počátku regenerace odlišnost mezi skupinami dle zálivky dále narůstala.

Ekotypy borovice lesní bylo možné odlišit jak z obrazových, tak laboratorních dat. Jak analýza rozptylu, smíšený statistický model, tak natrénování klasifikátorů potvrdily rozdíly mezi dvěma ekotypy. Rozdíly mezi ekotypy bylo možné zaznamenat i přes zvýšenou variabilitu mezi jedinci v obou skupinách navozenou stresem z nedostatku vody.

Hypotéza č. 1: ve spektrech semenáček borovice bude možné detekovat vodní stres, byla potvrzena.

Hypotéza č. 2: z laboratorních a obrazových spekter borovice lesní bude možné rozeznat různé ekotypy, byla také potvrzena.

Přínos této práce může být ve více oborech. Z hlediska spektroskopie a dálkového průzkumu Země může být zajímavá a nadále využitelná navržená metoda úpravy spekter pomocí fotografií semenáček. Jednoduchý skript dokázal podstatně snížit variabilitu v hodnotách odrazivosti způsobenou rozdílným pokrytím plochy zorného pole spektrometru semenáčkem borovice.

Při detekci vodního stresu u rostlin a stromů se v mnohých člancích nepracuje se středním infračerveným zářením v oblasti mezi 1000-2500 nm (např. Lien et al. 2019). V této práci byly vlnové délky a poměrové indexy, které měly nejvyšší hodnoty koeficientu determinace s obsahem vody v jehlicích, pozorovány právě v této oblasti. Z tohoto experimentu vyplývá nutnost pracovat s těmito vlnovými délkami pro robustní odhad obsahu vody v jehlicích borovice lesní.

Rozlišení proveniencí, ekotypů a genotypů borovice lesní s pomocí spektroskopie je věnováno velice málo vědeckých článků. V této práci byly (překvapivě) pozorovány poměrně vysoké přesnosti pro odlišení dvou ekotypů borovice lesní i přes zvýšenou variabilitu mezi jedinci. To může být motivem pro další práce v této oblasti a pro využití spektroskopie a dálkového průzkumu Země pro odlišení ekotypů borovice lesní v praxi.

Z biologického hlediska je zajímavé chování semenáček různých ekotypů ve fázi regenerace. Rozdíly mezi skupinami dle ošetření u náhorního ekotypu nebyly po třech týdnech regenerace detekovatelné, u pahorkatinného se rozdíly naopak ještě zvětšily. Lze vyvodit, že náhorní ekotyp se po etapě sucha lépe regeneruje, což může být předmětem dalších studií.

Na tuto práci lze navázat v mnohých směrech. Jednak lze zpřesňovat aparaturu na měření spekter. Další řešení si žádá především problém rozšiřujícího se zorného pole spektrometru. Pokud není snímán dvoudimenzionální předmět, vždy bude přepočítaná plocha z fotografie o jednotky nebo desítky procent špatně. Z hlediska detekce sucha u borovice lesní by bylo vhodné dále zkoumat, proč se skupina středního sucha nelišila od kontrolní skupiny. Buď byl rozdíl mezi skupinami tak nízký, že nebyl detekován pomocí spektrálních dat, nebo byla zálivka stále dostatečná pro udržení všech životních funkcí semenáčků v normálu. Hlubší výzkum by si zasloužilo chování semenáčků různých ekotypů ve fázi regenerace. Při hledání rozdílů mezi jedinci borovice lesní lze pokračovat v jednotlivých genotypech. Obrazová data ze semenných sadů byla již v této práci zpracována složitějším způsobem (extrakce spektrální charakteristiky každého jedince) právě z toho důvodu, aby mohly být extrahované spektrální křivky jednotlivých stromů v budoucnu využity k hledání rozdílů mezi genotypy, které se v semenných sadech vyskytují. Zjištěné vysoké přesnosti rozlišení ekotypů v této práci mohou podpořit další práce věnované tematice rozlišení druhů, proveniencí, ekotypů a genotypů borovice lesní.

6 Závěr

Prvním cílem této práce bylo navrhnout nedestruktivní způsob měření spekter semenáčků borovice lesní. Byla navržena aparatura, která minimalizovala šum v datech a která zajistila stejné podmínky při každém měření. Hodnoty odrazivosti semenáčků borovice byly korigovány s pomocí fotografií semenáčků, ze kterých byl spočítán poměr černého pozadí a borovice v zorném poli optického kabelu spektrometru. Vzhledem ke sníženému variačnímu koeficientu ve většině vlnových délek po úpravě spekter, přesným výsledkům dalších částí práce a porovnání s literaturou lze považovat soustavu za vhodnou pro nedestruktivní měření semenáčků borovice lesní, a to i přes některé nedostatky způsobu měření zmíněné v diskusi.

Druhým cílem práce bylo zjistit, zda se v laboratorních spektrech semenáčků borovice projeví vodní stres různé intenzity a zda se bude reakce borovic lišit dle ekotypu. Za tímto účelem byl proveden tříměsíční laboratorní experiment (22.4.–15.7.2021), při kterém byly rozděleny semenáčky dle dvou ekotypů (náhorní a pahorkatinný) a dle tří skupin závlivky (kontrola, střední sucho a silné sucho). Analýza spekter proběhla s pomocí analýzy rozptylu, smíšeného statistického modelu, analýzy hlavních komponent, natrénování čtyř klasifikátorů a vegetačních indexů. Od 10.6. (tedy po 8 týdnech) byl pozorován stres z nedostatku sucha u obou ekotypů (nárůstem signifikantně odlišných pásem u analýzy rozptylu, změnami v hodnotách vegetačních indexů). Nejvíce byla na obsah vody v jehlicích citlivá oblast středního infračerveného záření (1000-2500 nm). Stres se však projevil pouze u skupiny silné sucho. Skupiny kontrola a střední sucho se od sebe neodlišovaly. Po třech týdnech regenerace (15.7.) již u náhorního ekotypu nebyly pozorovány rozdíly mezi třemi skupinami závlivky. U pahorkatinného ekotypu se naopak rozdíly mezi skupinami dle ošetření ještě prohloubily. Vzhledem k výsledkům druhého cíle byla potvrzena hypotéza č. 1, že ve spektrech semenáčků borovice bude možné detekovat vodní stres.

Třetím cílem práce bylo zjistit, zda je možné v obrazových a laboratorních spektrech rozlišit rozdílné ekotypy borovice lesní. Obrazová spektra byla pořízena ze tří semenných sadů (semenné sady Doubrava, Holičky a Děčín) v létě roku 2020. Zda se ekotypy liší v laboratorních a obrazových spektrech bylo zjišťováno pomocí analýzy rozptylu, smíšeného statistického modelu a natrénováním čtyř klasifikátorů. Přesnost zařazení semenáčků do skupin dle ekotypů se u lineární diskriminační analýzy pohybovala mezi 87-99 %. Signifikantní rozdíly mezi ekotypy potvrdily také analýza rozptylu a smíšený statistický model. Z laboratorních dat byly ekotypy odlišitelné i přes vysokou variabilitu mezi jedinci způsobenou stresem z nedostatku vody. V průběhu laboratorního měření nebyly nalezeny výrazné výkyvy v přesnosti natrénování klasifikátorů dle dvou ekotypů. Vzhledem k výsledkům třetího cíle byla potvrzena hypotéza č. 2, že z laboratorních a obrazových spekter borovice lesní bude možné rozeznat různé ekotypy.

Výsledky práce mohou být využívány pro další zpřesnění výzkumu vlivu sucha na vegetaci s využitím laboratorní a obrazové spektroskopie. Poměrně přesný způsob měření spekter semenáčků borovic prezentovaný v této práci zatím nebyl jinde využit. Důležitým zjištěním je vysoká korelace hodnot odrazivosti v pásmech středního infračerveného záření (1000-2500 nm) s obsahem vody v jehlicích borovice lesní. Vysoké přesnosti odlišení dvou ekotypů borovice lesní získané různými využitými metodami mohou motivovat k dalšímu výzkumu v oblasti, ze které zatím nejsou četné vědecké publikace.

Z biologického hlediska je zajímavý vývoj jedinců z náhorního a pahorkatinného ekotypu po začátku regenerace. Z této práce vyplývá, že se jedinci náhorního ekotypu po etapě sucha regenerují lépe než pahorkatinného ekotypu. Pokud by tento výsledek byl potvrzen v dalších experimentech, mohl by to být indikátor výběru ekotypu borovice lesní k zalesnění oblastí sužovaných suchem.

Seznam literatury

van Aardt J., Wynne R. (2001): Spectral Separability among Six Southern Tree Species. *Photogrammetric Engineering and Remote Sensing*. 67 / 1367-1375.

van Aardt J., Wynne R. (2007): Examining pine spectral separability using hyperspectral data from an airborne sensor: An extension of field-based results. *International Journal of Remote Sensing*. 28 / 431-436.

Abdi H. (2003): Partial least squares (PLS) regression. V knize: Lewis-Beck M. (editor): *Encyclopedia of social sciences research methods*. str. 792 – 795.

Adão T., Hruška J., Pádua L., Bessa J., Peres E., Morais R., Sousa J. J. (2017): Hyperspectral Imaging: A Review on UAV-Based Sensors, Data Processing and Applications for Agriculture and Forestry. *Remote Sensing*. 9 / 1110.

Albrechtová J., Kupková L., Campbell P.K.E. (2017): Hodnocení stavu smrkových porostů. - Případové studie sledování vývoje fyziologického stavu smrkových porostů v Krušných horách v letech 1998 - 2013. *Geographica - Česká geografická společnost*. ISBN: ISBN 978-80-905642-9-9.

AVex (2019): Současný problém sucha v ČR. Expertní stanovisko AV ČR. Ústav výzkumu globální změny AV ČR, v. v. i., 3/2019.

Behmann J., Steinrücken J., Plümer L. (2014): Detection of early plant stress responses in hyperspectral images. *ISPRS Journal of Photogrammetry and Remote Sensing*. 93 / 98–111.

Bertels L., Deronde B., Kempeneers P., Debruyne W., Provoost S. (2021): Optimized Spectral Angle Mapper classification of spatially heterogeneous dynamic dune vegetation, a case study along the Belgian coastline. 9th International Symposium on Physical Measurements and Signatures in Remote Sensing (ISPMSRS). Peking, Čína.

Bolstad P., Lillesand T. M. (1991): Rapid maximum likelihood classification. *Photogrammetric engineering and remote sensing*. 57 / 67-74.

Bonansea M., Rodriguez M.C., Pinotti L., Ferrero S. (2015): Using multi-temporal Landsat imagery and linear mixed models for assessing water quality parameters in Río Tercero reservoir (Argentina). *Remote Sensing of Environment*. 158 / 28-41.

Buddenbaum H., Stern O., Paschmionka B., Hass E., Gattung T., Stoffels J., Hill J., Werner W. (2015): Using VNIR and SWIR field imaging spectroscopy for drought stress monitoring of beech seedlings, *International Journal of Remote Sensing*. 36 / 4590-4605.

Cavender-Bares J., Meireles J. E., Couture J. J., Kaproth M. A., Kingdon C. C., Singh A., Serbin S. P., Center A., Zuniga E., Pilz G. (2016): Associations of Leaf Spectra with Genetic and Phylogenetic Variation in Oaks: Prospects for Remote Detection of Biodiversity. *Remote Sensing*. 8 / 221.

Chatterjee S., Singh M., Biswal B. P., Sinha U. K., Patbhaje S., Sarkar A. (2019): Application of laser-induced breakdown spectroscopy (LIBS) coupled with PCA for rapid classification of soil samples in geothermal areas. *Analytical & Bioanalytical Chemistry*. 411 / 2855–2866.

Chávez R., Clevers J.G.P.W., Herold M., Ortiz M., Acevedo E. (2013): Modelling the spectral response of the desert tree *Prosopis tamarugo* to water stress. *International Journal of Applied Earth Observation and Geoinformation*. 21 / 53-65.

Chen W., An J., Li R., Fu L., Xie G., Bhuiyan M., Li K. (2018): A novel fuzzy deep-learning approach to traffic flow prediction with uncertain spatial-temporal data features, *Future Generation Computer Systems*. 89 / 78-88.

Conroy J., Smillie R., Küppers M., Bevege D., Barlow E. (1986): Chlorophyll a Fluorescence and Photosynthetic and Growth Responses of *Pinus radiata* to Phosphorus Deficiency, Drought Stress, and High CO₂. *Plant physiology*. 81 / 423-429.

Cregg B.M., Zhang J.W. (2001): Physiology and morphology of *Pinus sylvestris* seedlings from diverse sources under cyclic drought stress. *Forest Ecology and Management*. 154 / 131-139.

Červená L., Lysák J., Potůčková M., Kupková L. (2020): Zkušenosti se zpracováním hyperspektrálních dat pořízených UAV. GIS Ostrava 2020 – Prostorová data pro Smart City a Smart Region. Ostrava (CZ) 18. – 20. 3. 2020.

Dabboor M., Howell S., Shokr M., Yackel J. J. (2014): The Jeffries–Matusita distance for the case of complex Wishart distribution as a separability criterion for fully polarimetric SAR data. *International Journal of Remote Sensing*. 35 / 6859–6873.

Danusevicius D., Masaitis G., Mozgeris G. (2014): Visible and near infrared hyperspectral imaging reveals significant differences in needle reflectance among Scots pine provenances. *Silvae Genetica*. 63 / 169-180.

Dawson T., Curran P. (1998): A new technique for interpolating the reflectance red edge position. *International Journal of Remote Sensing*. 19 / 2133-2139.

De Diego N., Saiz-Fernández I., Rodríguez J.L., Pérez-Alfocea P., Sampedro M.C., Barrio R.J., Lacuesta M., Moncaleán P. (2015): Metabolites and hormones are involved in the intraspecific variability of drought hardening in *radiata* pine. *Plant Physiology*. 188 / 64–71.

Delaney J. K., Thoury M., Zeibel, J. G. (2016): Visible and infrared imaging spectroscopy of paintings and improved reflectography. *Heritage Science*. 4 / 6.

Deligoz A., Gur M. (2015): Morphological, physiological and biochemical responses to drought stress of Stone pine (*Pinus pinea* L.) seedlings. *Acta Physiologiae Plantarum*. 37 / 10.

Dobrovolný P. (1998): Dálkový průzkum Země: digitální zpracování obrazu. 1. vyd. Brno: Masarykova univerzita. ISBN: 80-210-1812-7

Dong X., Zhang Z., Yu R., Tian Q., Zhu X. (2020): Extraction of Information about Individual Trees from High-Spatial-Resolution UAV-Acquired Images of an Orchard. *Remote Sensing*. 12 / 133.

Fassnacht F. E., Stenzel S., Gitelson A. A. (2015): Non-destructive estimation of foliar carotenoid content of tree species using merged vegetation indices. *Journal of Plant Physiology*. 176 / 210-217.

FIS (2020): Fernerkundung in Schulen, Univerzita Bonn. [citováno 5.1.2021] Dostupné online: <<https://fis.uni-bonn.de/>>

Gao D., Gao Q., Xu H. (2009): Physiological responses to gradual drought stress in the diploid hybrid *Pinus densata* and its two parental species. *Trees*. 23 / 717.

Gates D. M., Keegan H. J., Schleter J.C., Weidner V.R. (1965): Spectral Properties of Plants. *Applied Optics*. 4 / 11-20.

Graybeal J. D. (1993): *Molecular Spectroscopy*. 2. vyd. New York: McGraw-Hill College. ISBN: 978-0070244122

Headwall (2021): Hyperspectral Sensors. [citováno 21.6.2021] Dostupné online: <<https://www.headwallphotonics.com/hyperspectral-sensors>>

Jackson R. D., Huete A. R. (1991): Interpreting vegetation indices. *Preventive Veterinary Medicine*. 11 / 185-200.

Jung A., Götze Ch., Cornelia G. (2012): Overview of Experimental Setups in Spectroscopic Laboratory Measurements – the SpecTour Project. *Photogrammetrie - Fernerkundung - Geoinformation*. 2012(4) / 433-442.

Kahraman S., Erturk A. (2018): Review and Performance Comparison of Pansharpening Algorithms for RASAT Images. *Journal of Electrical & Electronics Engineering*. 18 / 109-120.

Kaňák J., Klápště J., Lstibůrek M. (2009): Úvodní genetické hodnocení semenných sadů borovice lesní v západních. *Zprávy lesnického výzkumu*. 54 / 189-204.

Kaňák J. (2011): Návrh šlechtitelských postupů pro borovici lesní v západních a jižních Čechách. *Disertační práce. Česká zemědělská univerzita v Praze - Fakulta lesnická a dřevařská*. 148 s.

Kaňák, K. (1993): Alternativní řešení rekonstrukce lesa v imisních oblastech. *Lesnická práce*. 72 / 10-13.

Kiang M. Y. (2003): A comparative assessment of classification methods. *Decision Support Systems*. 35 / 441-454.

Kim S.R., Lee W.K., Lim C.H., Kim M., Kafatos M.C., Lee S.H., Lee S.S. (2018): Hyperspectral Analysis of Pine Wilt Disease to Determine an Optimal Detection Index. *Forests*. 9 / 115.

Kim T.K. (2015): T test as a parametric statistic. *Korean journal of anesthesiology*, 68(6) / 540–546.

Knipling E.B. (1970): Physical and physiological basis for the reflectance of visible and near-infrared radiation from vegetation. *Remote Sensing of Environment*. 3 / 155-159.

Kokaly R. F., Despain D. G., Clark R. N., Livo K. E. (2003): Mapping vegetation in Yellowstone National Park using spectral feature analysis of AVIRIS data. *Remote Sensing of Environment*. 84 / 437–456.

Kokaly, R. F., Clark R. N. (1999): Spectroscopic determination of leaf biochemistry using band-depth analysis of absorption features and stepwise multiple linear regression. *Remote Sensing of Environment*. 67 / 267–287.

Kolář J., Halounová L., Pavelka K. (1997): *Dálkový průzkum Země* 10. 1. vyd. Praha: Vydavatelství ČVUT. ISBN: 80-01-01567-X.

Korecký J. (2012): Establishment of the second-generation seed orchards of Scots pine. *Disertační práce. Česká zemědělská univerzita v Praze - Fakulta lesnická a dřevařská*. 128 s.

Lhotáková Z., Kopačková-Strnadová V., Oulehle F., Homolová L., Neuwirthová E., Švik M., Janoutová R., Albrechtová J. (2021): Foliage Biophysical Trait Prediction from Laboratory Spectra in Norway Spruce Is More Affected by Needle Age Than by Site Soil Conditions. *Remote Sensing*. 13 / 391.

Lien M., Barker R., Ye Z., Westphall M., Gao R., Singh A., Gilroy S., Townsend P. (2019): A low-cost and open-source platform for automated imaging. *Plant Methods*. 15 / 6.

Maccioni A., Agati G., Mazzinghi P. (2001): New vegetation indices for remote measurement of chlorophylls based on leaf directional reflectance spectra. *Journal of Photochemistry and Photobiology*. 61 / 52-61.

Madritch M., Kingdon C., Singh A., Mock K., Lindroth R., Townsend P. (2014): Imaging spectroscopy links aspen genotype with below-ground processes at landscape scales. *Philosophical transactions of the Royal Society of London. Series B, Biological sciences*. 369 / 1643.

Malenovský Z., Homolová L., Zurita-Milla R., Lukeš P., Kaplan V., Hanuš J., Gastellu-Etchegorry J. P., Schaepman M. E. (2013): Retrieval of spruce leaf chlorophyll content from airborne image data using continuum removal and radiative transfer. *Remote Sensing of Environment*. 131 / 85-102.

Manes F., Donato E., Vitale M. (2001): Physiological Response of *Pinus Halepensis* Needles under Ozone and Water Stress Conditions. *Physiologia Plantarum*. 113 / 249–257.

Matovič A. (1992): Stavba dřeva. 1. vyd. Brno: Vysoká škola zemědělská v Brně. ISBN 80-7157-019-2.

Meng Q., Cieszewski C.J., Madden M., Borders B.E. (2007): K Nearest Neighbor Method for Forest Inventory Using Remote Sensing Data. *GIScience and Remote Sensing* 44 / 149-165.

Morán J., Mitchell A.K., Goodmanson G., Stockburger K.A. (2000): Differentiation among effects of nitrogen fertilization treatments on conifer seedlings by foliar reflectance: A comparison of methods. *Tree physiology*. 20 / 1113-1120.

Natesan S., Armenakis C., Benari G., Lee R. (2018): Use of UAV-Borne Spectrometer for Land Cover Classification. *Drones*. 2 / 16.

Neuwirthová E., Lhotáková Z., Albrechtová J. (2017): The Effect of Leaf Stacking on Leaf Reflectance and Vegetation Indices Measured by Contact Probe during the Season. *Sensors*. 17 / 1202.

Oommen T., Misra D., Sahoo B., Bandopadhyay S., Twarakavi N. K. C., Prakash A. (2021): An objective analysis of support vector machine based classification for remote sensing. *Mathematical Geosciences*. 40 / 409–424.

Opti-Sciences (200?): CCM-300. [citováno 23.6.2021] Dostupné online: <<https://www.optisci.com/ccm-300.html>>

Pearson M., Saarinen M., Nummelin L., Heiskanen J., Roitto M., Sarjala T., Laine J. (2013): Tolerance of peat-grown Scots pine seedlings to waterlogging and drought: Morphological, physiological, and metabolic responses to stress. *Forest Ecology and Management*. 307 / 43-53.

Peñuelas J., Gamon J. A., Fredeen A. L., Merino J., Field C. B. (1994): Reflectance indices associated with physiological changes in nitrogen- and water-limited sunflower leaves. *Remote Sensing of Environment*. 48 / 135-146.

Potůčková M., Červená L., Kupková L., Lhotáková Z., Lukeš P., Hanuš J., Novotný J., Albrechtová J. (2016): Comparison of Reflectance Measurements Acquired with a Contact Probe and an Integration Sphere: Implications for the Spectral Properties of Vegetation at a Leaf Level. *Sensors*. 16 / 1801.

Prosser V. (1989): Experimentální metody biofyziky. 1. vyd. Praha: Academia. ISBN 80-200-0059-3.

Provazník D. (2021): Kvantifikace genetické variability multispektrální reflektance v rámci lokálních populací borovice lesní. Diplomová práce. Česká zemědělská univerzita v Praze - Fakulta lesnická a dřevařská. 91 s.

Schneider W.E., Young R. (1997): Spectroradiometry Methods. V knize: de Cusatis C. (editor): Handbook of Applied Photometry. str. 252.

Schowengerdt R. E. (2007): Remote Sensing: Models and Methods for Image Processing. 3. vyd. Burlington: Academic Press. ISBN 978-0-12-369407-2.

Semerci A., Semerci H., Çalışkan B., Çiçek N., Ekmekçi Y., Mencuccini M. (2017): Morphological and physiological responses to drought stress of European provenances of Scots pine. *European Journal of Forest Research*. 136 / 91-104.

Slaton M.R., Hunt E.R., Smith W.K. (2001): Estimating near-infrared leaf reflectance from leaf structural characteristics. *American Journal of Botany*. 88 / 278–284.

Spectrum Technologies (2021): WaterScout SM 100. [citováno 23.6.2021] Dostupné online: <<https://www.specmeters.com/weather-monitoring/sensors-and-accessories/sensors/soil-moisture-sensors/sm100/>>

Stimson H., Breshears D., Ustin S., Kefauver S. (2005): Spectral sensing of foliar water conditions in two co-occurring conifer species: *Pinus edulis* and *Juniperus monosperma*. *Remote Sensing of Environment*. 96 / 108-118.

Stahle L., Wold S. (1989): Analysis of variance (ANOVA). *Chemometrics and Intelligent Laboratory Systems*. 6 / 259-272.

Stuart M. B., McGonigle A. J. S., Willmott J. R. (2019): Hyperspectral Imaging in Environmental Monitoring: A Review of Recent Developments and Technological Advances in Compact Field Deployable Systems. *Sensors*. 19 / 3071.

Sundblad L., Andersson M., Geladi P., Salomonson A., Sjöström M. (2001): Fast, nondestructive measurement of frost hardness in conifer seedlings by VIS plus NIR spectroscopy. *Tree physiology*. 21 / 751-757.

Šindelář J. (1991): Koncepce dalšího šlechtění borovice lesní (*Pinus sylvestris* L.) pro potřeby ČR. *Práce VÚLHM* 76 / 7-46.

Tucker J.C. (1978): A comparison of satellite sensor bands for vegetation monitoring. *Photogrammetric Engineering and Remote Sensing*, 44 (11) / 1369–1380.

Vorovencii, I. (2009): The hyperspectral sensors used in satellite and aerial remote sensing. *Bulletin of the Transilvania University of Braşov*. 2 / 51-56.

Wang X., Zeng Y., Wang S. (2015): Identification of Conifer Species Based on Laboratory Spectroscopy and an Artificial Neural Network. *Journal of Software Engineering*. 9 / 362-372.

Wu C., Niu Z., Tang Q., Huang W. (2008): Estimating chlorophyll content from hyperspectral vegetation indices: Modeling and validation. *Agricultural and Forest Meteorology*. 148 / 1230-1241.

Xiangchao M., Huanfeng S., Huifang L., Liangpei Z., Randi F. (2019): Review of the pansharpening methods for remote sensing images based on the idea of meta-analysis: Practical discussion and challenges. *Information Fusion*. 46 / 102-113.

Xu Q., Ni Y., Defo M., Dalpke B., Sherson G. (2011): Predictions of wood density and module of elasticity of balsam fir (*Abies balsamea*) and black spruce (*Picea Mariana*) from near infrared spectral analyses. *Canadian Journal of Forest Research*. 41 / 352-358.

Xun L., Wang L. (2015): An object-based SVM method incorporating optimal segmentation scale estimation using Bhattacharyya Distance for mapping salt cedar (*Tamarisk spp.*) with QuickBird imagery. *GIScience & Remote Sensing*. 52 / 257-273.

Yang H., Du Q., Ma B. (2010): Decision Fusion on Supervised and Unsupervised Classifiers for Hyperspectral Imagery. *IEEE Geoscience and Remote Sensing Letters*. 7 / 875-879.

Zhang, F., Zhou, G. (2019): Estimation of vegetation water content using hyperspectral vegetation indices: a comparison of crop water indicators in response to water stress treatments for summer maize. *BMC Ecol*. 19 / 18.

Zhang N., Wang Y., Zhang X. (2020): Extraction of tree crowns damaged by *Dendrolimus tabulaeformis* Tsai et Liu via spectral-spatial classification using UAV-based hyperspectral images. *Plant Methods*. 16 / 135.

Zhang Y., Chen J., Miller J., Noland T. (2008): Retrieving chlorophyll content in conifer needles from hyperspectral measurements. *Canadian Journal of Remote Sensing*. 34 / 290-311.


Přílohy

Seznam příloh


Příloha 1: Semenáčky borovice lesní ve skleníku KEBR, PŘF UK.	87
Příloha 2: ANOVA dle ekotypů 22.4.2021 (1. měření).....	87
Příloha 3: ANOVA dle ekotypů 6.5.2021 (3. měření).....	87
Příloha 4: ANOVA dle ekotypů 13.5.2021 (4. měření).....	88
Příloha 5: ANOVA dle ekotypů 20.5.2021 (5. měření).....	88
Příloha 6: ANOVA dle ekotypů 27.5.2021 (6. měření).....	88
Příloha 7: ANOVA dle ekotypů 3.6.2021 (7. měření).....	88
Příloha 8: ANOVA dle ekotypů 10.6.2021 (8. měření).....	88
Příloha 9: ANOVA dle ekotypů 17.6.2021 (9. měření).....	88
Příloha 10: ANOVA dle ekotypů 30.6.2021 (11. měření).....	89
Příloha 11: ANOVA dle ekotypů 15.7.2021 (12. měření).....	89
Příloha 12: ANOVA dle míry zálivky 29.4.2021 (2. měření).....	89
Příloha 13: ANOVA dle míry zálivky 6.5.2021 (3. měření).....	89
Příloha 14: ANOVA dle míry zálivky 13.5.2021 (4. měření).....	89
Příloha 15: ANOVA dle míry zálivky 20.5.2021 (5. měření).....	89
Příloha 16: ANOVA dle míry zálivky 27.5.2021 (6. měření).....	90
Příloha 17: ANOVA dle míry zálivky 3.6.2021 (7. měření).....	90
Příloha 18: ANOVA dle míry zálivky 10.6.2021 (8. měření).....	90
Příloha 19: ANOVA dle míry zálivky 17.6.2021 (9. měření).....	90
Příloha 20: ANOVA dle míry zálivky 30.6.2021 (11. měření).....	90
Příloha 21: Přesnosti natrénování klasifikátorů (nezávisle na ekotypu, 2 skupiny ošetření - silné sucho, zbytek).....	91
Příloha 22: Přesnosti natrénování klasifikátorů (náhorní ekotyp, 3 skupiny ošetření).....	91
Příloha 23 : Přesnosti natrénování klasifikátorů (pahorkatinný ekotyp, 3 skupiny ošetření).....	91
Příloha 24: Obsah přiloženého DVD	92




Příloha 1: Semenáčky borovice lesní ve skleníku KEBR, PřF UK.




Příloha 2: ANOVA dle ekotypů 22.4.2021 (1. měření)




Příloha 3: ANOVA dle ekotypů 6.5.2021 (3. měření)




Příloha 4: ANOVA dle ekotypů 13.5.2021 (4. měření)




Příloha 5: ANOVA dle ekotypů 20.5.2021 (5. měření)




Příloha 6: ANOVA dle ekotypů 27.5.2021 (6. měření)




Příloha 7: ANOVA dle ekotypů 3.6.2021 (7. měření)




Příloha 8: ANOVA dle ekotypů 10.6.2021 (8. měření)




Příloha 9: ANOVA dle ekotypů 17.6.2021 (9. měření)




Příloha 10: ANOVA dle ekotypů 30.6.2021 (11. měření)




Příloha 11: ANOVA dle ekotypů 15.7.2021 (12. měření)




Příloha 12: ANOVA dle míry zálivky 29.4.2021 (2. měření)




Příloha 13: ANOVA dle míry zálivky 6.5.2021 (3. měření)




Příloha 14: ANOVA dle míry zálivky 13.5.2021 (4. měření)




Příloha 15: ANOVA dle míry zálivky 20.5.2021 (5. měření)




Příloha 16: ANOVA dle míry zálivky 27.5.2021 (6. měření)




Příloha 17: ANOVA dle míry zálivky 3.6.2021 (7. měření)



Příloha 18: ANOVA dle míry zálivky 10.6.2021 (8. měření)



Příloha 19: ANOVA dle míry zálivky 17.6.2021 (9. měření)



Příloha 20: ANOVA dle míry zálivky 30.6.2021 (11. měření)

Měření	Datum	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	KNN means
1	22.dub	0,7195	0,5732	0,7073	0,5244
2	29.dub	0,5610	0,6098	0,6951	0,5488
3	06.kvě	0,5610	0,4634	0,6585	0,5854
4	13.kvě	0,7073	0,5122	0,6585	0,5976
5	20.kvě	0,6463	0,4878	0,6585	0,6098
6	27.kvě	0,7317	0,5000	0,6585	0,6220
7	03.čvn	0,6098	0,4512	0,6585	0,6098
8	10.čvn	0,8659	0,5732	0,6829	0,5854
9	17.čvn	0,7561	0,6341	0,7561	0,5488
10	24.čvn	0,7805	0,6829	0,7195	0,5488
11	30.čvn	0,7875	0,5750	0,7250	0,6500
12	15.čvc	0,6538	0,7179	0,7179	0,6667

Příloha 21: Přesnosti natrénování klasifikátorů (nezávisle na ekotypu, 2 skupiny ošetření - silné sucho, zbytek)

Měření	Datum	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	KNN means
1	22.dub	0,3415	0,3415	0,3659	0,2683
2	29.dub	0,2927	0,2927	0,4634	0,1951
3	06.kvě	0,3902	0,2439	0,4146	0,1220
4	13.kvě	0,4634	0,2683	0,2927	0,4146
5	20.kvě	0,4146	0,3902	0,4146	0,3171
6	27.kvě	0,3659	0,3902	0,2439	0,3659
7	03.čvn	0,4390	0,5366	0,4878	0,4146
8	10.čvn	0,5366	0,3659	0,4634	0,3415
9	17.čvn	0,4390	0,2195	0,4146	0,3659
10	24.čvn	0,4146	0,2927	0,4878	0,2683
11	30.čvn	0,5128	0,5128	0,4872	0,2308
12	15.čvc	0,3590	0,2821	0,4615	0,4359

Příloha 22: Přesnosti natrénování klasifikátorů (náhorní ekotyp, 3 skupiny ošetření)

Měření	Datum	Linear Discriminant Analysis	Naive Bayes	Support Vector Machine	KNN means
1	22.dub	0,5610	0,3902	0,5610	0,4390
2	29.dub	0,5366	0,4146	0,5610	0,4146
3	06.kvě	0,5854	0,4390	0,5366	0,4390
4	13.kvě	0,6098	0,4146	0,5122	0,4634
5	20.kvě	0,6098	0,3659	0,4634	0,6341
6	27.kvě	0,5610	0,5122	0,4634	0,5854
7	03.čvn	0,5122	0,4146	0,5854	0,3415
8	10.čvn	0,6341	0,4878	0,5122	0,3902
9	17.čvn	0,6585	0,4878	0,5610	0,2195
10	24.čvn	0,5122	0,4878	0,5366	0,4634
11	30.čvn	0,4390	0,4390	0,4878	0,5366
12	15.čvc	0,4359	0,5385	0,5385	0,5897

Příloha 23 : Přesnosti natrénování klasifikátorů (pahorkatinný ekotyp, 3 skupiny ošetření)

Příloha 24: Obsah přiloženého DVD

Priloha1_skripty

- sady_clas.py

Skript určený k provedení klasifikace KNN na všech pásech obrazových dat ze semenných sadů.

- Vstupní data: Hyperspektrální snímky ze semenných sadů
- Výstupní data: Snímky klasifikované metodou KNN (8 tříd)

- sady_extrakce.py

Skript určený ke spočítání průměru, mediánu a směrodatné odchylky odrazivosti z každé vlnové délky pro určitý strom. Tento modelový skript byl určený pro sad v Děčíně.

- Vstupní data: Hyperspektrální snímky ze semenných sadů, klasifikované snímky metodou KNN, vrstva s polygony bufferů kolem jednotlivých borovic
- Výstupní data: Textové soubory s hodnotami průměrné hodnoty, mediánu a směrodatné odchylky odrazivosti pro každou vlnovou délku a každý strom

- prepocet_borovic.m

Skript určený k přepočítání hodnot odrazivosti s pomocí fotografií semenáčků borovic.

- Vstupní data: Fotografie borovic (formát .jpg), textový soubor s trénovacími pixely z fotografií borovic, protokol s čísly vzorků měřených borovic, textový soubor s hodnotami odrazivosti v každé vlnové délce pro každý vzorek
- Výstupní data: Excelový soubor (.xlsx) s hodnotami odrazivosti pro každou vlnovou délku a každý vzorek po úpravě s pomocí fotografie

Priloha2_text_prace

- Text práce